

中图法分类号: TP751 文献标识码: A 文章编号: 1006-8961(2024)06-1714-16

论文引用格式: Ding C, Chen J Y, Zheng M M, Zhang L, Wei W and Zhang Y N. 2024. Survey of hyperspectral image change detection method. Journal of Image and Graphics, 29(06):1714-1729(丁晨, 陈静怡, 郑萌萌, 张磊, 魏巍, 张艳宁. 2024. 高光谱图像变化检测技术研究进展. 中国图象图形学报, 29(06):1714-1729)[DOI:10.11834/jig.240031]

高光谱图像变化检测技术研究进展

丁晨¹, 陈静怡¹, 郑萌萌¹, 张磊², 魏巍², 张艳宁^{2*}

1. 西安邮电大学计算机学院, 西安 710121; 2. 西北工业大学计算机学院, 西安 710072

摘要: 相对于自然图像和多光谱图像, 高光谱图像包含丰富的空间-光谱信息, 不仅能够保留目标的空间信息, 还能够获取高度可辨别的光谱信息。因此, 如变化检测、目标追踪等高光谱图像处理技术在对地观测任务中得到了广泛应用。然而, 在高光谱图像变化检测的过程中仍然存在许多问题与挑战。如高光谱图像的高维复杂性、光谱差异性以及存在光谱混合等问题, 影响变化检测效果。得益于深度学习理论的深入研究, 高光谱图像变化检测技术研究得到了极大的发展。本文对现有基于深度学习的变化检测方法进行全面分析总结, 按照高光谱图像采集条件是否相同, 将其分为同构高光谱图像变化检测以及异构高光谱图像变化检测。其中, 从特征提取的网络结构优化和特征提取前混合像素处理两个角度, 又将同构高光谱图像变化检测方法进一步分为基于时序依赖和空谱信息提取的方法以及基于端元提取和解混的方法, 分别总结各类方法的特点和局限性, 并讨论未来的研究重点。此外, 面对不同传感器获取的异构高光谱图像数据, 现有的方法基于图论学习图像的结构关系, 并基于图像变换将其转换至公共域从而进行变化检测处理。本文从高光谱图像变化检测领域的新设计、新方法和应用场景出发, 通过综合国内外前沿文献来梳理该领域的主要发展, 重点论述高光谱图像变化检测领域的发展现状、前沿动态、热点问题及趋势。

关键词: 高光谱图像; 变化检测; 时序特征提取; 端元解混; 异构高光谱图像变化检测

Survey of hyperspectral image change detection method

Ding Chen¹, Chen Jingyi¹, Zheng Mengmeng¹, Zhang Lei², Wei wei², Zhang Yanning^{2*}

1. School of Computer Science, Xi'an University of Posts and Telecommunications, Xi'an 710121, China;

2. School of Computer Science, Northwestern Polytechnical University, Xi'an 710072, China

Abstract: Compared with natural and multispectral images, hyperspectral images contain rich spatial-spectral information. They not only can retain the spatial information of the target but also can obtain highly distinguishable spectral information and provide more detailed target feature information. Therefore, hyperspectral images have become one of the most commonly used data types for Earth observation and are widely used in important fields that actually affect human livelihoods, such as natural disaster monitoring, urban landscape mapping, agricultural surveys, environmental management, and homeland security. Change detection refers to the timely observation of land cover changes by analyzing images of the same geographical area and different phases. It is one of the important research directions in remote sensing image processing. With the increasing popularity and application of remote sensing technology, various remote sensing image processing technologies such as target detection and change detection have played an indispensable role in Earth observation tasks, such as natural disaster monitoring, agricultural surveys, environmental management, and homeland security. The impor-

收稿日期: 2024-01-30; 修回日期: 2024-02-20; 预印本日期: 2024-02-27

* 通信作者: 张艳宁 ynzhang@nwpu.edu.cn

基金项目: 国家自然科学基金项目(62372379, 62101454, 61901369, 62071387)

Supported by: National Natural Science Foundation of China (62372379, 62101454, 61901369, 62071387)

tant areas for exploration are as follows. Many problems and challenges still exist in the process of change detection in hyperspectral images. On the one hand, hyperspectral images have a large number of spectral bands, which leads to too high dimensions of data. This condition easily causes dimensionality disaster. Moreover, processing high-dimensional data requires a high degree of computing resources. Therefore, in real application scenarios, hyperspectral image change detection is difficult to achieve. Data processing and method design are often easily limited by device storage performance and computing performance. On the other hand, hyperspectral images acquired at different time points may have differences in spectral response due to factors such as illumination and atmospheric conditions. They may also have inconsistencies in resolution and spatial location, which increases the complexity of change detection. Spectral mixing is also one of the important challenges facing hyperspectral change detection. Pixels in hyperspectral data may contain a variety of ground object information, which seriously interferes with the accuracy of change detection. In addition, with the rapid development of hyperspectral remote sensing technology, equipment such as drones and satellites continue to collect a large number of hyperspectral images for use in important fields such as disaster monitoring, mineral exploration, and homeland security. However, differences exist in the shooting angle, height, and resolution of the sensors configured on different devices, and the acquired hyperspectral images also have distinctions in data structures. The existing isomorphism-based change detection methods for hyperspectral images cannot be directly applied to heterogeneous hyperspectral image change detection task. Therefore, the problem of change detection in heterogeneous hyperspectral images from different types of sensors also brings new challenges to hyperspectral image change detection. Therefore, alleviating the highly complex data characteristics of hyperspectral images and designing practical and effective processing solutions are important to improve the change detection effect. Among existing change detection methods for hyperspectral images, traditional methods usually use manually designed methods for feature extraction, which may fail to effectively extract discriminative features, and selecting appropriate thresholds to accurately detect land cover changes is difficult. Research on change detection technology for hyperspectral images has been greatly developed due to in-depth research on deep learning theory. Existing change detection methods based on deep learning can be roughly divided into two categories. One is based on temporal dependence and spatial spectrum information. The extraction method uses the temporal dependence and correlation between images to obtain more discriminative features and enhance the change detection performance. The other type is the method based on endmember extraction and unmixing, which is solved by the endmember extraction and unmixing method. Spectral mixing problem for hyperspectral images aims to improve change detection accuracy. In addition, in the face of heterogeneous hyperspectral image data acquired from different sensors such as drones and satellites, existing methods learn the structural relationships of heterogeneous images based on graph theory. They convert them into the public domain based on image transformation to make changes. With regard to detection and processing, certain temporal dependencies and correlations exist between multiple input images in the change detection task. Thus, effectively utilizing the temporal dependencies and correlations between images and combining the existing deep learning module design to improve the hyperspectral image change detection effect are also current issues. Regarding the research hotspots, this study starts from the new designs, new methods, and application scenarios in the field of hyperspectral image change detection, and the main developments in this field are sorted out by synthesizing domestic and foreign cutting-edge literature. First, it introduces the key preprocessing technologies for hyperspectral image change detection. Second, for the problem of isomorphic hyperspectral image change detection, traditional and deep learning-based methods for hyperspectral image change detection are introduced, and each type of method is systematically introduced and compared according to the different implementation methods. For heterogeneous hyperspectral image change detection and spectral image change detection problem, this study introduces and summarizes the existing heterogeneous change detection methods for hyperspectral images. Next, the current status of application of change detection methods for hyperspectral images in real industrial practice is discussed. Finally, the current research and development status at home and abroad is compared, and the development trend of hyperspectral image change detection is prospected.

Key words: hyperspectral image; change detection; temporal feature extraction; endmember unmixing; heterogeneous hyperspectral image change detection

0 引言

本文主要介绍高光谱图像变化检测领域的新设计、新方法和应用场景,通过综合国内外前沿文献从数据预处理、变化检测方法研究现状和现实应用分析3方面介绍该领域的主要发展。

变化检测指通过分析同一地理区域、不同时相的图像来及时观测土地覆盖的变化,是遥感图像处理的重要研究方向之一。随着遥感技术的日益普及和应用,目标检测、变化检测等多种遥感图像处理技术在对地观测任务中发挥了不可或缺的作用。如图1所示,与多光谱图像和合成孔径雷达图像相比,高光谱图像具有高光谱分辨率,蕴含丰富的空间—光谱信息,能够提供更详细的目标地物信息。因此,高光谱图像已成为对地观测最常用的数据类型之一,并在自然灾害监测、城市景观制图、农业调查、环境管理和国土安全等切实影响人类生计的重要领域得到广泛应用。

然而,高光谱图像变化检测同时也面临着诸多挑战。一方面,高光谱图像具有大量的光谱波段,导致数据的维度过高,容易造成维度灾难;并且,处理高维数据需要高度的计算资源,因此,在现实应用场景中,高光谱图像变化检测的数据处理及方法设计往往容易受到设备存储性能、计算性能等限制。另一方面,不同时间点获取的高光谱图像可能由于光照、大气条件等因素而存在光谱响应的差异,并且可能在分辨率、空间位置等方面存在不一致性,进而增加变化检测的复杂性。光谱混合也是高光谱变化检测面临的重要挑战之一,高光谱数据中的像元可能包含多种地物信息,严重干扰变化检测的准确性。此外,针对来自不同类型传感器(基于卫星、无人机等)的异构高光谱图像变化检测问题也给高光谱图像变化检测带来了新的挑战。因此,如何缓解高光谱图像高度复杂的数据特性,设计切实有效的处理方案提升变化检测效果至关重要。

现有的高光谱图像变化检测方法中,传统方法通常采用手动设计的方式进行特征提取,可能无法有效地提取具有判别性的特征,并且难以选择适当的阈值来准确检测土地覆盖变化。近年来,得益于深度学习的长足发展与广泛应用,基于深度学习的高光谱图像变化检测方法也随之得到了研究者的

广泛关注与深入研究。现有基于深度学习的方法主要分为两类,一类方法利用多时相高光谱图像的时序依赖与空间—光谱信息进行变化检测;另一类方法通过设计端元提取与解混方法与深度学习网络模型相结合。此外,针对异构高光谱图像变化检测任务,现有的方法则多为基于变换的方法,将不同传感器获取的高光谱图像变换至公共域再进行处理。由于变化检测任务多个输入图像间具有一定的时序依赖性与关联性,因此,如何有效利用图像间的时序依赖与关联性,结合现有的深度学习模块设计提升高光谱图像变化检测效果也是当前的研究热点之一。

本文首先对高光谱图像变化检测的关键预处理技术进行介绍。其次,针对同构高光谱图像变化检测问题,分别介绍高光谱图像变化检测的传统方法及基于深度学习的方法,并对每类方法按照实现方式的不同进行系统性介绍与对比;针对异构高光谱图像变化检测问题,对现有异构高光谱图像变化检测方法进行介绍及总结。接着,对现实产业实践中应用高光谱图像变化检测方法的现状进行探讨。最后,对比国内外研究发展现状并对高光谱图像变化检测的发展趋势进行展望。




图1 多光谱图像及高光谱图像

Fig. 1 Multispectral image and hyperspectral image
(a) multispectral image; (b) hyperspectral image)

1 高光谱图像的数据预处理

数据预处理对于高光谱图像变化检测任务具有

至关重要的作用。由于噪声、大气干扰、光照变化和其他不确定因素可能会对变化检测的性能产生负面影响。因此,在高光谱图像变化检测任务中,数据预处理的主要目的是尽可能地消除图像中的冗余信息,获得适合分析的数据,以便后续更好地识别地表变化。如图 2 所示,针对高光谱图像变化检测的数据预处理一般包括辐射校正、几何校正和图像配准。

1.1 辐射校正

由于太阳角度、大气等不同的成像条件,导致高光谱图像在同一区域的光谱特征出现差异,从而干扰变化检测过程。辐射校正旨在校正高光谱图像的辐射度量,以确保图像中的辐射值与地表物体的辐射特性成比例,从而获得准确的地物辐射信息。一般可分为绝对辐射校正和相对辐射校正。

绝对辐射校正是指将高光谱图像的数字值转化为真实的辐射亮度或反射率,一般可包括大气校正、灰度校正、辐射度量单位标定和传感器响应校正等

步骤,以确保图像中的数值与地物的辐射特性成比例。FLAASH (fast line-of-sight atmospheric analysis of spectral hypercubes)校正模型是常见的高光谱图像大气校正模型之一,其目的是纠正图像中的大气散射和吸收效应。6s(second simulation of the satellite signal in the solar spectrum)校正模型适用于多光谱或高光谱图像大气校正,其建立了光线在大气中的传播过程的详细物理模型,考虑了大气光学厚度、大气散射、大气吸收和太阳照射角度等因素,可以获得更准确的校正效果。BRDF (bidirectional reflectance distribution function)校正绝对是辐射校正的一部分,通常与大气校正一起使用,用于纠正遥感图像中的双向反射特性。其使用物理模型来模拟光线的相互作用,通常采用辐射传输模型,以预测不同角度下的反射率。然而,绝对辐射校正通常涉及复杂的物理模型和计算过程,并且需要提供准确的观测几何信息和大气参数,这些数据可能不容易获取且地面测量成本较高。因此,易于计算的相对辐射校正




图 2 高光谱图像数据预处理方法架构图

Fig. 2 Architecture diagram of hyperspectral image data preprocessing methods

是更常用的处理方式。

相对辐射校正是指消除不同时间点或不同传感器拍摄的遥感图像之间的辐射度量单位和亮度的差异,以确保它们在可比的尺度上进行比较。一般包括灰度校正和传感器响应校正,用来调整图像的数字值,进行可比性分析。直方图匹配法是相对辐射校正的一种方法,用于调整图像的亮度和对比度,以匹配参考图像或标准光谱曲线。图像回归法的核心思想是建立图像值与地表参数之间的关系模型,其形式可以是线性回归、多元线性回归、非线性回归或其他适当的数学模型,使用该模型可将图像值转化为地表参数。伪不变特征法通过提取伪不变特征并建立校正模型,将遥感图像转化为一致的亮度和对比度。

1.2 几何校正

高光谱图像在采集过程中由于传感器变化、地球自转等因素,会导致图像中的像素位置与地理位置不匹配。几何校正是在高光谱图像发生几何畸变时进行的校正,包括系统校正和精确校正。系统校正旨在校正由传感器系统和平台运动引起的常规几何失真,包括像元的旋转、扭曲、比例变化和图像畸变等。比例尺系数方法是解决由于传感器系统引起的比例尺变化问题的常用方法。通过计算比例尺系数并建立比例尺校正模型,可以将图像中的所有像元的大小进行校正。平行移动方法通过计算位置偏移并进行平行移动校正,可以更准确地定位图像中的地理特征。

精确校正范围不仅包括系统性失真,还包括由于地球曲率、地形变化和大气延迟等外部失真。其主要方法有地面控制点和几何校正模型。

1.3 图像配准

高光谱图像配准是变化检测的基础,是指对不同时间、不同传感器或不同平台获取的高光谱图像进行地理坐标匹配的过程。配准误差会导致高光谱图像变化检测中出现许多伪变化区域,严重影响检测结果。图像配准算法可分为基于区域的配准和基于特征的配准。

基于区域的配准侧重于将图像分成不同的区域,利用图像像素的灰度信息进行配准。当图像中存在几何变化或变形时,可以提供较好的配准精度。主要包括相关系数法、互信息法、极大似然匹配法和快速傅里叶变换法。相关系数法首先选择

具有最少几何变形的图像作为参考图像,通过其他图像与参考图像之间的像素值相关性来确定空间变换参数,之后将该参数应用于待配准图像实现配准。互信息法的核心思想是最大化两幅图像之间的互信息进行配准,它可以处理图像之间的非线性变换,但是计算较为复杂,并且对噪声敏感。极大似然匹配法利用统计模型来描述图像块之间的相似性,通过最大化两幅图像之间的似然度实现配准。快速傅里叶变换法通过使用频域分析和傅里叶变换来确定最佳的空间变换参数进行配准,适用于需要处理平移、旋转和缩放等线性变换的情况。

基于特征的配准通过寻找和匹配图像对中的特征点或特征描述建立匹配关系,从而进行图像配准。主要包括时域边缘检测法、变换域边缘检测法和图像分割法。时域边缘检测法旨在识别图像中的水平或垂直边缘,提取这些边缘作为特征,从不同图像之间进行匹配。变换域边缘匹配可以在变换域中捕获图像中的结构信息,通过提取变换域边缘信息确定图像之间的空间变换参数。图像分割法首先将待配准图分成多个块,对每个图像块进行图像分割,以提取图像中的具有明显特征或结构的区域,之后进行区域配准。

2 传统的高光谱变化检测方法

变化检测方法通常将两个(或多个)图像作为输入,经过图像预处理、特征提取、降维、差异比较、决策规则应用和图像后处理等步骤(每个步骤可选择性执行),最终生成一个二值图像,即变化差异图,用于标识变化的像素,这一过程如图3所示。其中,特征提取是决定变化检测效果的关键步骤。

传统的高光谱变化检测方法通过手工设计特征提取方法获得不同时相高光谱图像像素之间的相似性,从而进行差异比较得到变化检测结果。传统的方法包括基于代数的方法、基于转换的方法、基于光谱分析的方法和基于后分类的方法。

2.1 基于代数的方法

Bovolo 和 Bruzzone(2007)提出的光谱变化矢量分析(change vector analysis, CVA)是图像代数中的一种经典方法,主要通过计算多时相光谱矢量之间的距离来获得变化的幅度和方向。但是,高光谱图像的光谱变异性可能会影响光谱变化矢量分析方法

的检测结果。因此,许多研究者提出了相应的改进策略。

Bovolo 等人(2012)提出压缩变化向量分析(compressed change vector analysis, C²VA)用于多光谱图像的变化检测,通过压缩所有可用的光谱通道的信息,提供一个二维极坐标域的压缩变化表示。但由于高光谱图像的高维度性,使其具有更高的计算成本与更复杂的变化表示。Liu 等人(2014)提出序列光谱变化向量分析(sequential spectral change vector analysis, S²CVA),以迭代的方式连续分析变化向量,具有多个变更信息模型,并在每次迭代中分层识别,从而获得更为精确的变化状态。Liu 等人(2015b)提出了一种基于序列光谱变化矢量分析的改进方法,设计了二维自适应表示来可视化变化。在每个层级上,这种表示都通过自定义增强变化部

分的参考向量对序列光谱特征进行优化。最后,应用交互式手动更改识别来提取自适应光谱变化矢量表示域中的变化部分。为了获得更准确的变化类数,Liu 等人(2015)还提出了一种基于分层聚类的光谱变化矢量分析方法。上述方法虽然充分利用了光谱信息,但空间利用率相对有限,并且由于孤立像元的光谱异常变化和配准误差,可能会增加模糊度,导致检测误差增大。因此,许多研究者提出了一些引入空间信息的方法。Liu 等人(2017)提出了一种多尺度形态压缩变化向量分析方法,通过结合光谱信息和空间信息来表征高光谱图像多尺度变化。Vongsy 和 Mendenhall(2016)提出了一种最大似然相关系数来融合光谱信息和空间信息。但基于代数的方法在识别多类变化检测和选择适当的阈值获取准确差异比较结果上仍然存在困难。




图3 变化检测处理过程示意图

Fig. 3 Schematic diagram of change detection processing process

2.2 基于转换的方法

基于转换的方法可以将高光谱图像转换至低维特征空间,以区分变化部分和非变化部分。基于转换的方法中,一种典型的变化检测方法为图像变换,主要通过将高光谱图像高维原始空间中的特征映射到新的低维子空间中,以加强变化区域和未变化区域的区分。Nielsen 和 Müller(2003)提出多元变化检测(multivariate alteration detection, MAD),其采用统计学中的典型相关分析方法,通过寻找光谱波段的线性组合之间的差异,并强调解释最大方差的正交差异来得到检测结果。Frank 和 Canty(2003)提出了一种基于典型相关分析的高光谱图像变化检测方法,该方法采用无监督多元变化检测技术突出多元

变化信息,从而检测多时相高光谱图像中的季节性植被变化。Nielsen(2007)提出的迭代重加权的多元变化检测(iteratively reweighted multivariate alteration detection, IR-MAD)扩展了多元变化检测(multivariate alteration detection, MAD)的性能,其通过赋予非变化特征更高的权重,生成非变化背景来提高检测性能。

主成分分析(principal component analysis, PCA)是目前最流行的子空间学习算法之一,但其严重依赖于图像的统计特性,易受到不平衡数据的影响。Ortiz-Rivera 等人(2006)提出一种基于时间的主成分分析方法(temporal principal component analysis, TPCA)的高光谱变化检测方法,如图4所示,其中每个时间序列的高光谱图像被认为是一个随机变量,

主成分分析应用于这些变量之间的协方差矩阵,方差最大的主成分与共同信息相关联,方差最小的主成分与变化信息相关联。

由于不正确选择阈值会影响变化检测算法的性

能。Baisantry 等人(2012)提出了一种增强主成分光谱变化矢量分析(PCA-CVA),通过主成分差异和反三角函数相结合来选择适当的阈值,重构高光谱图像以获得更准确的检测结果。




图4 基于时间主成分分析的高光谱变化检测方法(Ortiz-Rivera等,2006)

Fig. 4 Change detection in hyperspectral imagery using temporal principal component analysis (Ortiz-Rivera et al., 2006)

2.3 基于光谱分析的方法

基于光谱分析的方法通过检测双时相图像像素之间所有波段的光谱距离或形状的差异来进行变化检测。欧氏距离、光谱角映射器、光谱相关测度和光谱信息发散等度量方法广泛用于测量光谱特征之间的差异。Wu 等人(2013)提出了一种基于子空间的高光谱图像变化检测方法,利用相应像素邻域的空间信息和光谱信息来构建背景子空间,采用正交子空间投影计算子空间距离以确定目标相对于背景子空间是否异常。

2.4 基于后分类的方法

基于后分类的变化检测方法是一种常见的变化检测分析方法。其使用两个或更多的数据集来创建变化映射。基于后分类的方法通常包括两个步骤:1)对每个数据集进行单独分类;2)对每个分类的结果进行相互比较,最后生成变化图像。该类方法最大的优点之一是,因为每个数据集都是单独分类的,因此,可以适应来自不同传感器的数据。一般来说,基于后分类的方法可以分为有监督分类方法和无监督分类方法,两者的区别在于监督分类方法需要多时相图像数据与真实差异结果数据对分类器进行训练。Bovolo 等人(2008)提出一种无监督的变化检测方法,旨在从多时相图像的原始特征空间中联合分析光谱通道,以提取变化信息,并通过使用选择性贝叶斯阈值处理来选择伪训练集,对于伪训练集使用未标记模式定义变化和未变化像素的决策边界。

然而,这类方法的检测精度很大程度上依赖于分类精度,并且容易忽略双时相图像之间的相关性,导致检测结果不理想。

3 基于深度学习的高光谱变化检测方法

传统方法虽然在高光谱图像变化检测问题上取得了一定效果,但是通常仅使用原始的浅层特征,在面对一些复杂场景时检测性能较差。并且仅检测发生变化的区域,忽略了对变化区域的进一步分析。近年来,基于深度学习的高光谱图像变化检测研究得到了极大的发展。现有的方法主要分为两类,一类方法利用多时相高光谱图像的时序依赖与空间—光谱信息进行变化检测。时序信息和丰富的空间—光谱信息在变化检测中具有重要作用,地表的变化通常是一个动态过程,随着时间的推移,地物可能会发生变化。考虑时序信息可以确保检测到的变化是持续性的,而非瞬时的噪声或干扰,从而提高检测的准确性。同时,通过跟踪地物随时间的变化,可以获得有关地表动态的更多见解,对于预测未来变化和采取适当的措施具有重要作用。另一类方法通过设计端元提取与解混方法与深度学习网络模型相结合。由于传感器的限制,高光谱图像一个像素内可能包含多种地物的混合光谱信号,形成混合像元。直接对混合像元的光谱进行比较可能会因为混合效应而产生假阳性结果。通过设计端元提取和解混方法可以消除由混合像元引起的混淆,更准确地区分“真实”变化(如植被类型改变)与非变化因素(如光照条件变化)导致的光谱差异,从而提高变化检测的精度。

3.1 基于时序依赖和空谱信息提取的深度学习方法

高光谱图像同时包含丰富的光谱信息和空间信

息,叶珍等人(2021)论述了空间—光谱特征提取对于高光谱图像处理的重要性。因此,针对具体下游任务,如变化检测,提取充分的空间—光谱信息也是降低检测过程中不确定性和提高检测结果准确性的重要途径之一。传统的高光谱图像变化检测方法大多只考虑每个像素的光谱信息,而忽略了空间信息的利用。卷积神经网络(convolutional neural network, CNN)可以通过学习图像的局部特征来有效地捕捉输入数据的空间结构,因此,研究者引入卷积神经网络获取高光谱图像中的空间信息,提高变化检测的准确性。Li 等人(2021)提出将结构相似性(structural similarity index measure, SSIM)和变化向量分析(CVA)相结合生成可信的标签,训练卷积神经网络,以学习双时相高光谱图像中像素的空间—光谱特征。Zhao 等人(2022)提出了一种基于简化三维卷积自编码器的高光谱变化检测方法,该方法采用深度无监督自编码器,可以在不需要先验信息的情况下从双时相图像中提取深度空间—光谱特征。并通过增加三维卷积核,去除池化层,简化了三维卷积神经网络的结构,减少频谱冗余,提高数据处理速度。最后,使用一个添加了二维卷积层的softmax分类器来获得检测结果,该方法只需要少量的标签样本就可以训练分类器。Li 等人(2019)提出了一种基于噪声建模的无监督全卷积网络(fully convolutional network, FCN)高光谱变化检测框架,可以提取更具判别性的空间—光谱特征,同时,引入噪声建模也使得模型更具有鲁棒性。

由于双时相遥感图像变化检测的输入为两幅图像,因此,许多方法采用孪生网络结构对图像对进行特征提取。孪生网络结构一般由两个结构相同的子网络组成,即特征提取器,将输入的双时相图像转换为特征映射。这种结构的主要优点是其两个子网络是同时训练的,共同学习输入图像对的特征表示。根据子网络的权值是否共享,可分为纯孪生网络结构和伪孪生网络结构。樊玮等人(2020)采用孪生网络结构,分别从参考图像和查询图像中提取不同网络层的深度特征,并且融合了图像的高级语义特征来克服变化检测中的检测噪音。类似地,孪生网络结构在更为具体的高光谱图像变化检测领域也应用广泛。

如图5所示,Zhan 等人(2021)提出了一种基于孪生网络架构的空间—光谱卷积神经网络的高光谱

图像变化检测框架。首先将高光谱图像输入到孪生网络—卷积神经网络架构中提取像素级浅层空间—光谱特征向量,然后计算两个向量的欧氏距离对其相似性进行表征。最后,将所有特征向量对输入模型,得到结果并判断每一像素是否属于变化区域。

上述方法大多侧重于调整网络架构或添加额外的手工设计模块来改进卷积神经网络,导致网络结构较为复杂,参数庞大,计算成本也大大提高。Wang 等人(2022a)提出一种端到端的残差自校准网络来提高高光谱图像变化检测的精度。该方法自适应地构建每个空间位置的空间和光谱间依赖关系,可以更充分地利用空间信息,同时减少额外的参数,降低了计算复杂性。此外,嵌套在卷积层中的卷积滤波器,有助于生成更多的判别表示。

人类的视觉系统可以选择性地集中关注图像中显眼的成分,而忽略其他不显眼的部分。注意力机制受人类视觉系统的启发,可以将可用的处理资源分配给输入信号中信息量最大的部分,还具有通过对输入信号设置适当的权值关注重要分量并抑制无关分量的特性。高光谱图像包含大量的光谱信息,不同的光谱通道和输入图像块的空间位置可能会对变化检测处理产生不同的影响。然而,在以往基于卷积神经网络的方法中,并没有对不同的光谱通道包含的信息重要程度进行区分。Wang 等人(2021)提出了一种具有空间—光谱智能注意力机制的端到端孪生卷积神经网络,该方法可以突出重要信息的光谱通道和空间位置,并且从输入的图像块中自适应地细化空间—光谱特征。Yang 等人(2022)提出了一种基于空间—光谱残差注意力增强的深度多尺度金字塔网络,该方法使用多尺度金字塔卷积来提取多尺度的空间—光谱特征,每个尺度的特征经过增强的空间—光谱残差注意力模块处理,以进一步提取空间—光谱特征。最后将多尺度特征逐层聚合,从而获得多层次的特征表示。Wang 等人(2023)提出了一种注意力引导的特征融合网络,该网络利用光谱注意模块和空间注意模块分别提取重要的光谱和空间特征,之后对提取的多级特征进行融合,将多维特征作为一个整体考虑,抑制了不同层次特征之间的语义差距和位置差异,增强了识别变化特征的能力。Qu 等人(2021)提出了一种增强空间—光谱残差注意的深度多尺度金字塔网络,首次将图卷积网络引入高光谱图像变化检测中。该方法采用双

分支图卷积网络有效地提取判别性特征,并设计了差异放大模块,用于抑制相似区域,突出双分支结构中多时相高光谱图像之间的特征差异,从而增加了变化类和不变化类之间的区别。Hu 等人(2022)提出一种像素级自监督空间—光谱特征理解网络,将

整个图像输入至网络中,逐像素比较多时相空间—光谱特征,并且使用空间—光谱注意模块分别探索多时相高光谱图像的空间相关性和判别光谱特征,而不是以混合方式处理二维成像空间和光谱响应维度。




图5 基于孪生网络架构的空间—光谱卷积神经网络的高光谱图像变化检测方法(Zhan 等, 2021)

Fig. 5 A spectral-spatial convolution neural network with Siamese architecture for change detection (Zhan et al. , 2021)

变化检测任务通常涉及到监测地表变化,而许多变化都是周期性的,如农田的季节性变化、植被的生长和凋落等。而时序信息可以提供更多的上下文信息,帮助模型更好地理解地表的演化过程和学习变化趋势,对周期性变化和微小变化的检测具有重要作用。

Shi 等人(2022)通过设计长短期记忆网络和卷积神经网络的并行架构来学习双时态高光谱图像之间的多级时间依赖性,提取多尺度时间-空间—光谱特征。Song 等人(2018)提出了一种递归的 3-D 全卷积网络,该网络通过三维卷积层提取空间—光谱特征,采用长短期记忆网络(long short-term memory, LSTM)提取时序信息,同时利用主成分分析(PCA)和谱相关角(spectral correlation angle, SCA)生成高概率变化或不变的训练样本。但是,与二维卷积核相比,三维卷积核具有更多的参数,从而使网络复杂度和训练时间迅速增加。Chen 等人(2023)提出一种时间差分引导的高光谱图像变化检测网络,首先从双时相图像中分层提取丰富的光谱特征,之后通过空间维度上设计的卷积门控循环单元块来产生网络不同层次的图像对之间的差异。其可以充分利用网络在不同层次上获得的时间差异,并进一步利用这些信息来促进网络对变化特征的关注和提取。

如图 6 所示, Song 等人(2022)提出了一种跨时相交交互对称注意网络,该网络可以有效地提取和整合高光谱图像的时间—空间联合特征,同时增强对

变化的特征识别能力。具体而言,其整体采用孪生网络结构,以对称模式分层提取变化信息。设计了跨时间交互对称注意模块来与双时相高光谱图像信息交互,该模块结合自注意力机制来增强不同时间点图像的特征表示能力,并利用跨时间注意模块来整合不同时间点特征嵌入所指向的差异特征。

循环神经网络在连续的时间步骤中使用神经激活之间的循环连接,其中隐藏层和记忆细胞可以长时间存储过去的信息。Lyu 等人(2016)使用基于改进的长短期记忆模型的端到端循环神经网络用于多/高光谱变化检测,改进的长短期记忆模型可以获取并记录长序数据的变化信息。证明了循环神经网络框架和长短期记忆模型可以学习稳定的变化规则。这种方法在不需要额外学习的情况下,在目标图像之间具有良好的可移植性。

自注意力模型最初主要应用于自然语言处理领域,但因其出色的中长期依赖关系建模能力,近年来也广泛应用于变化检测任务,以增强特征之间的时间相关性和全局关系。Wang 等人(2022b)提出一种联合光谱—空间—时间自注意力模型,具体而言,通过对高光谱图像的每个像素进行位置编码以保留光谱和空间序列,之后使用光谱自注意力模块和空间自注意力模块分别提取光谱和空间信息,最后将不同时间点的高光谱图像特征输入到时间自注意力模块中,提取图像对之间有用的特征。Shafique 等人(2023)提出一种混合空间—光谱卷积视觉自注意力




图6 基于跨时相交对称注意力网络的高光谱图像变化检测方法(Song等,2022)

Fig. 6 Cross-temporal interaction symmetric attention network for hyperspectral image change detection (Song et al. , 2022)

模型,并通过使用不同的方法生成高置信度伪样本用于模型训练。将卷积神经网络和自注意力网络的优点相结合,可以模拟全局依赖关系,挖掘序列特征。Zhang等人(2023)提出了一种用于高光谱图像变化检测的级联频谱感知自注意力模型,其中,时空自注意力模块考虑了特征之间的时间相关性,用于提取有效的时空信息。光谱感知自注意力模块用以更好地挖掘和表示光谱特征的序列属性,特别是中长期依赖关系。Li和Ding(2023)提出一种光谱—时间自注意力网络模型,通过多头自注意力机制捕获光谱—时间特征,建立全局光谱—时间感受野,学习两个频带之间的不同代表性特征,从而加强对时间变化信息的学习。

尽管基于时序依赖和空谱信息提取的高光谱图像变化检测方法充分利用了高光谱图像所蕴含的丰富特征及多时相图像间的时序关系,但时序依赖的处理与引入,也增加了模型的复杂度。其次,时序信息处理不当,容易使得模型学习到冗余信息,导致模型鲁棒性不足。因此,如何有效提取多时相高光谱图像间的时序关系,设计简单有效的变化检测框架是该类方法的关键。

3.2 基于端元提取和解混的深度学习方法

高光谱图像中的像元通常包含多个地物的混合信号,其提供丰富地物信息的同时也增加了处理难度,影响检测效果。因此,如何提取图像中纯净、可识别的光谱特征,为后续的变化检测提供基准,也是

重点研究方向之一。

Du等人(2005)提出了一种光谱解混变化检测的通用框架,该方法基于线性解混模型,即高光谱图像中的像素反射率是图像场景中存在的所有端元的线性混合。Jafarzadeh和Hasanlou(2019)提出一种基于光谱解混的无监督二值多变化检测方法,先估计端元数,提取端元,计算丰度,并应用相似度评估识别对应端元;之后区分纯变化像素以及混合变化像素,将它们的结果合并,生成二值变化图;最后根据公式标记变化的像素并生成多重变化图。常规光谱解混的过程中仍存在两个重要问题,即难以估计端元数量,以及提取端元本身的过程中,其结果会根据所使用的提取方法而有所不同。稀疏解混的目的是找到光谱库特征的最佳子集,以将高光谱数据集的像素表示为这些特征的线性组合,可用于缓解以上两个问题。Ertürk等人(2016)首次将稀疏解混在多时相高光谱数据分析和变化检测中进行应用,基于光谱库的稀疏解混变化检测不仅可以提供高光谱数据的像素级变化信息,而且还可以提供亚像素级变化信息,多时相数据集中发生的变化在亚像素级上表示为像素内潜在端元的丰度,或这些端元在整个场景中的分布变化。Chen和Wang(2017)提出了一种频谱空间正则化低秩和稀疏分解的变化检测模型,将光谱变化向量分解为3个部分:局部平滑的低秩矩阵用于纯净变化特征;稀疏矩阵用于离群值;误差矩阵用于小的高斯噪声。

但是仅通过光谱解混创建的丰度图无法有效地提供详细的变化信息,Guo 等人(2021a)提出了一种基于联合解混和信息协同策略的多时相高光谱图像变化检测方法,采用多时态联合解混方法实现端元提取和丰度估计;并通过多时态协同引导方法在多时态第一主成分图和丰度差异图之间传递公共结构信息,以此来突出变化区域和未变化区域之间的对比度并去除噪声,实现多时相空间信息的有效组合。

如图7所示,Hu 等人(2023)提出了一种无监督二元变化引导高光谱图像多类变化检测网络,旨在利用二元变化检测方法提高多类变化检测结果和解混结果。其设计了一种多时相光谱解混的联合解混模块,提出以二值变化检测结果伪标签为导向的时间相关约束,从变化检测的角度指导解混过程,使未变化像元的丰度更具有相关性,变化像元的丰度更加精确。




图7 基于二元变化引导高光谱图像多类变化检测方法(Hu 等, 2023)

Fig. 7 Binary change guided hyperspectral multiclass change detection (Hu et al., 2023)

Li 等人(2022)提出了一种基于多端元光谱分解、联合矩阵和卷积神经网络的集成变化检测方法。首先通过多端元光谱解混获得更可靠的端元丰度信息,之后使用联合矩阵算法将原始图像特征与丰度图像结合起来,以提供更多的时空土地覆盖变化信息特征,最后通过卷积神经网络有效地提取变化特征并更好地处理融合的多源信息。Dong 等人(2023)提出了一种基于分层多头自交叉混合注意力的丰度矩阵相关分析网络模型,将双时相高光谱图像之间的变化信息映射到相应的丰度矩阵中,并通过不断比较丰度矩阵之间的自相关和互相关来提取增强的差异特征。

上述方法虽然有一定的效果,但是亚像素级的端元丰度信息往往没有得到充分利用。Liu 等人(2016b)提出了一种在亚像素级研究光谱一时间变化的多时相光谱解混方法,该方法设计了双时相光谱混合模型来分析像素内的光谱组成,提取多时相

端元之后,并提出了变化分析策略来区分变化端元和未变化端元,最后通过分析变化类和未变化类的丰度及其对每个像素的贡献,进行多时相变化检测。Wang 等人(2019)提出了一种通用的端到端二维卷积神经网络,可以更好地处理高光谱图像的高维问题以及挖掘更丰富的信息。该方法引入融合亚像素表示的混合亲和矩阵,将两个一维像素向量转换为二维矩阵用于变化检测任务,提供了更丰富的跨通道梯度信息。在此基础上设计了二维卷积神经网络框架,将高光谱图像和丰度图融合在一起,以处理不同因素引起的变化。Guo 等人(2021b)将像素级在空间利用方面的优势和亚像素级在时间和频谱探索方面的优势相结合,提出了一种通过卷积稀疏分析和时间光谱分解来进行高光谱图像变化检测的方法。

相比于基于时序依赖和空谱信息提取的方法,基于端元提取和解混的方法具有对地物的高度可解

释性和对地物组合的较好适应性。然而,该类方法仍存在一些局限,如端元提取具有复杂性,以及模型在新场景中的泛化困难,导致不同地区之间的地物变化检测效果不一致等问题。因此,如何更好地结合自监督方法、无监督方法等增强基于端元提取和解混的方法面对新应用场景的泛化能力是研究的重点。

4 异构高光谱图像变化检测方法

随着高光谱遥感技术日新月异的发展,如无人机、卫星等设备不断采集大量的高光谱图像应用于灾害监测、矿产勘探和国土安全等重要领域。然而,不同设备所配置传感器的拍摄角度、高度及分辨率存在差异,所获取到的高光谱图像也存在数据结构间的差异,现有的基于同构的高光谱变化检测方法无法直接适用于异构高光谱图像变化检测任务。因此,异构高光谱图像变化检测方法也是近期的研究热点之一。

现有的基于异构的高光谱图像变化检测方法多为基于变换的方法,将来源于不同传感器的高光谱图像结合图论表示异构高光谱图像的数据结构,并变换至公共域进行变化检测处理。Xiao等人(2022)提出了一种基于变化对齐的无监督异构变化检测框架,在图像域变换过程中深入利用前向差分图和后向差分图的互补信息,增强了域变换的效果,从而提高了高光谱图像变化检测的性能。该方法中,为了减少网络模型对标记样本的依赖,还设计了一种基于图结构的先验信息生成的策略来引导网络模型的学习过程。为了减少异构高光谱图像结构不对称性的影响,Sun等人(2023)提出了一种基于结构回归融合的方法,将不同时相的图像转换至公共域,分别计算其前向差分图和后向差分图。与过去方法不同,该方法设计了3种不同类型的约束来执行融合图像域转换:基于结构一致性的回归项、变化平滑度和基于对齐的融合项,以及基于稀疏性的惩罚项,充分探索前向差分图和后向差分图之间的关联性,从而提高域转换性能,获得更好的变化检测结果。

已有的异构高光谱图像变化检测方法通过对特定数据集的设计与实验,在一定程度上解决了处理不同传感器高光谱图像数据的问题。然而,面对未来可能出现的新型传感器或不同配置的高光谱图像,仍需要具备更强通用性的算法以适应不同的传

感器组合。因此,如何整合多源信息,提高异构高光谱图像变化检测方法的通用性和鲁棒性仍待学者们深入研究。

5 高光谱图像变化检测的应用

在实际应用中,高光谱图像变化检测可用于公共空间管理、建筑变化检测、环境和生物变化、森林检测以及自然灾害评估等方面。

城市化是引起地表变化的重要因素之一,可将自然土地覆盖转化为城市设施。Lyu等人(2018)使用基于迁移学习和循环神经网络的城市区域提取和变化检测框架,通过预测城市分布图中的差值来获得城市变化情况,在北京、纽约、墨尔本和慕尼黑4个目标城市上进行应用,其城市地图的总体精度约为96%。Nourani等人(2018)使用人工神经网络来检测土地利用和土地覆盖的变化,并通过检测变化位置研究其对出口径流的影响。Lyu等人(2017)使用一种基于直方图曲线拟合的方法来预测参数并确定阈值范围,并提出改进的区域增长算法构造最终的变化检测图像用于土地覆盖变化检测。Liu等人(2018)使用一种基于约束形状特征的方法进行建筑变化检测,通过整合像素形状特征和线段来提高建筑物和其他地面物体之间的可辨别性。Daudt等人(2018)提供了一个新的城市变化检测数据集,并在此数据集上分别使用孪生卷积网络和早期融合卷积网络架构进行检测,其精确度最高可达89%。

环境和生物变化是与我们每个人息息相关的。珊瑚礁是海洋生物最丰富的栖息地之一,对于各种鱼类、软体动物等海洋生物的生存至关重要,并且能够减缓风暴潮、波浪和海潮的影响,保护沿海地区免受自然灾害的侵害。因此,珊瑚礁环境变化监测具有重要意义。Zhou等人(2018)使用一种基于对象的变化检测方法用于监测珊瑚礁环境变化,该方法框架包括图像融合、多时间图像分割、图像差分、随机森林模型和基于对象区域的精度评估,其平均准确率超过90%。Mandanici和Bitelli(2015)提出了一种基于植被指数计算分类策略的自动程序,用于监测1987—2013年干旱环境中的耕种扩展情况,其变化检测总体准确率可达91%。Liu等人(2016a)使用一种迭代交叉分析算法用于底特律河国际野生动物保护区2001—2010年芦苇地区变化检测。其使用

合适的阈值通过密度切片获得粗略的土地覆盖区域,并利用叠加分析方法获取10年间共同的芦苇信息,结合其他土地覆盖类型的训练样本,采用有监督的分类方法检测芦苇面积的变化。结果表明,在10年间芦苇的分布面积从5 156亩增加到6 817亩,说明芦苇入侵仍然是保护生物多样性的一个严重挑战。Misbari 和 Hashim(2016)利用变化检测技术观测浅海沿岸海草生物量的变化情况,结果表明,2009年海草总生物量为 803 ± 0.47 kg,2013年为 752.3 ± 0.34 kg,4年时间内减少了50.7 kg。分析其主要原因可能是在潮滩地区填海造地,以增加港口设施和沿海景观发展。

自然灾害评估通常是灾害重建的第一步,评估损害的程度有助于制定风险管理以及为制定灾后恢复计划提供基础。早期灾害评估通常需要派遣专家实地细致绘制,进而对灾害情况做出评估。但随着诸如 Sentinel、ASTER 或 Landsat 等卫星可用于地面数据拍摄,在灾害发生前后几乎可以实时获取影像,变化检测技术可以利用事件前和事件后的数据帮助识别受损区域。现有的研究主要包括海啸、洪水、火灾和地震。Sublime 和 Kalinicheva(2019)以2011年东北地震和海啸前后的卫星图像为例,通过联合自动编码器来检测潜在变化区域,并进一步对该区域使用聚类算法突出变化,以评估损害的程度和严重性,其准确率可达85%。

6 结 语

本文对近年来高光谱图像变化检测领域的发展进行总结。从数据预处理、变化检测方法研究以及现实应用3方面介绍该领域的主要发展。数据预处理主要通过辐射校正、几何校正和图像配准的方法对高光谱图像进行处理,减少由于大气干扰、光线变化等因素对检测性能产生的负面影响。目前高光谱图像变化检测方法可分为传统方法和基于深度学习的方法。传统的高光谱变化检测方法通过手工提取特征,根据像素之间的相似性来检测变化,但在特征提取过程中可能无法有效地提取判别性特征,并且难以选择合适的阈值来检测土地覆盖变化。而基于深度学习的方法,一方面,通过对图像进行解混处理并进行端元提取;另一方面,利用图像间的时序依赖性和关联性,与深度学习网络模型相结合,可以有效

提取判别性特征,大大提升检测性能。总体而言,针对高光谱图像变化检测中存在的问题进行了细致的研究与探讨,提出了多种解决方案,使高光谱图像变化检测领域的新方法层出不穷。但是,在高光谱图像变化检测任务中仍存在许多问题需要继续探讨。如何基于时序信息的引入设计高效的变化检测框架,以及新应用场景下,如何增强现有基于端元提取和解混的方法的泛化能力都是值得研究的方向之一。此外,针对异构高光谱图像变化检测任务,如何整合多源信息,结合切实有效的预处理方法,提高图像配准精度,增强异构图像间域转换,设计通用性与鲁棒性更强的变化检测方法也是值得深入研究的方向之一。

综上所述,高光谱图像变化检测领域在近年来取得了蓬勃的发展,但是需要解决的新问题也不断涌现,在高光谱图像变化检测领域未来的工作中,应当把握热点方向,为解决高光谱图像中的新问题提出合理的解决方案。

致 谢 本文由中国图象图形学学会成像探测与感知专业委员会组织撰写,该专委会链接为<https://www.csig.org.cn/16/201704/49321.html>。

参考文献(References)

- Baisantriy 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]
- Bovolto F and Bruzzone L. 2007. A theoretical framework for unsupervised change detection based on change vector analysis in the polar domain. *IEEE Transactions on Geoscience and Remote Sensing*, 45(1): 218-236 [DOI: 10.1109/TGRS.2006.885408]
- Bovolto 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]
- Bovolto F, Marchesi S and Bruzzone L. 2012. A framework for automatic and unsupervised detection of multiple changes in multitemporal images. *IEEE Transactions on Geoscience and Remote Sensing*, 50(6): 2196-2212 [DOI: 10.1109/TGRS.2011.2171493]
- Chen Z and Wang B. 2017. Spectrally-spatially regularized low-rank and sparse decomposition: a novel method for change detection in multitemporal hyperspectral images. *Remote Sensing*, 9(10): #1044 [DOI: 10.3390/rs9101044]
- Chen Z H, Wang Y Y, Gao H M, Ding Y, Zhong Q Q, Hong D F and

- Zhang B. 2023. Temporal difference-guided network for hyperspectral image change detection. *International Journal of Remote Sensing*, 44 (19) : 6033-6059 [DOI: 10.1080/01431161.2023.2258563]
- Daudt R C, Le Saux B, Boulch A and Gousseau Y. 2018. Urban change detection for multispectral earth observation using convolutional neural networks//*Proceedings of 2018 IEEE International Geoscience and Remote Sensing Symposium*. Valencia, Spain: IEEE: 2115-2118 [DOI: 10.1109/IGARSS.2018.8518015]
- Dong W Q, Zhao J Y, Qu J H, Xiao S, Li N, Hou S X and Li Y S. 2023. Abundance matrix correlation analysis network based on hierarchical multihead self-cross-hybrid attention for hyperspectral change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #5501513 [DOI: 10.1109/TGRS.2023.3235401]
- Du Q, Wasson L and King R. 2005. Unsupervised linear unmixing for change detection in multitemporal airborne hyperspectral imagery//*Proceedings of 2005 International Workshop on the Analysis of Multi-Temporal Remote Sensing Images*. Biloxi, USA: IEEE: 136-140 [DOI: 10.1109/AMTRSI.2005.1469856]
- Ertürk A, Iordache M D, and Plaza A. 2016. Sparse unmixing-based change detection for multitemporal hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9 (2) : 708-719 [DOI: 10.1109/JSTARS.2015.2477431]
- Fan W, Zhou M and Huang R. 2020. Multiscale deep features fusion for change detection. *Journal of Image and Graphics*, 25(4): 669-678 (樊玮, 周末, 黄睿. 2020. 多尺度深度特征融合的变化检测. *中国图象图形学报*, 25(4): 669-678) [DOI: 10.11834/jig.190312]
- Frank M and Canty M. 2003. Unsupervised change detection for hyperspectral images//*Proceedings of the 12th JPL Airborne Earth Science Workshop*. Pasadena, USA: JPL Publication: 63-72
- Guo Q L, Zhang J P and Zhang Y. 2021a. Multitemporal hyperspectral images change detection based on joint unmixing and information coguidance strategy. *IEEE Transactions on Geoscience and Remote Sensing*, 59 (11) : 9633-9645 [DOI: 10.1109/TGRS. 2020.3045799]
- Guo Q L, Zhang J P, Zhong C X and Zhang Y. 2021b. Change detection for hyperspectral images via convolutional sparse analysis and temporal spectral unmixing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 4417-4426 [DOI: 10.1109/JSTARS.2021.3074538]
- Hu M Q, Wu C and Zhang L P. 2022. HyperNet: self-supervised hyperspectral spatial-spectral feature understanding network for hyperspectral change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60, #5543017 [DOI: 10.1109/TGRS. 2022.3218795]
- 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]
- Jafarzadeh H and Hasanlou M. 2019. An unsupervised binary and multiple change detection approach for hyperspectral imagery based on spectral unmixing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12 (12) : 4888-4906 [DOI: 10.1109/JSTARS.2019.2939133]
- Li H S, Wu K and Xu Y. 2022. An integrated change detection method based on spectral unmixing and the CNN for hyperspectral imagery. *Remote Sensing*, 14(11): #2523 [DOI: 10.3390/rs14112523]
- Li Q X, Gong H, Dai H, Li C L, He Z P, Wang W J, Feng Y S, Han F, Tuniyazi A, Li H Y and Mu T K. 2021. Unsupervised hyperspectral image change detection via deep learning self-generated credible labels. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 9012-9024 [DOI: 10.1109/JSTARS.2021.3108777]
- Li X L, Yuan Z H and Wang Q. 2019. Unsupervised deep noise modeling for hyperspectral image change detection. *Remote Sensing*, 11(3): #258 [DOI: 10.3390/rs11030258]
- Li X R and Ding J G. 2023. Spectral-temporal Transformer for hyperspectral image change detection. *Remote Sensing*, 15(14): #3561 [DOI: 10.3390/rs15143561]
- Liu H F, Yang M H, Chen J, Hou J L and Deng M. 2018. Line-constrained shape feature for building change detection in VHR remote sensing imagery. *ISPRS International Journal of Geo-Information*, 7(10): #410 [DOI: 10.3390/ijgi7100410]
- Liu H X, Meng X L, Jiang T, Liu X X and Zhang A B. 2016a. Change detection of phragmites australis distribution in the detroit wildlife refuge based on an iterative intersection analysis algorithm. *Sustainability*, 8(3): #264 [DOI: 10.3390/su8030264]
- Liu S C, Bruzzone L, Bovolo F and Du P J. 2014. A novel sequential spectral change vector analysis for representing and detecting multiple changes in hyperspectral images//*Proceedings of 2014 IEEE Geoscience and Remote Sensing Symposium*. Quebec, Canada: IEEE: 4656-4659 [DOI: 10.1109/IGARSS.2014.6947531]
- Liu S C, Bruzzone L, Bovolo F and Du P J. 2015a. Hierarchical unsupervised change detection in multitemporal hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 53 (1) : 244-260 [DOI: 10.1109/TGRS.2014.2321277]
- Liu S C, Bruzzone L, Bovolo F, Zanetti M and Du P J. 2015b. Sequential spectral change vector analysis for iteratively discovering and detecting multiple changes in hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 53 (8) : 4363-4378 [DOI: 10.1109/TGRS.2015.2396686]
- Liu S C, Bruzzone L, Bovolo F and Du P J. 2016b. Unsupervised multitemporal spectral unmixing for detecting multiple changes in hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(5): 2733-2748 [DOI: 10.1109/TGRS.2015.2505183]
- Liu S C, Du Q, Tong X H, Samat A, Bruzzone L and Bovolo F. 2017. Multiscale morphological compressed change vector analysis for

- unsupervised multiple change detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(9): 4124-4137 [DOI: 10.1109/JSTARS.2017.2712119]
- Lyu H B, Lu H and Mou L C. 2016. Learning a transferable change rule from a recurrent neural network for land cover change detection. *Remote Sensing*, 8(6): #506 [DOI: 10.3390/rs8060506]
- Lyu H B, Lu H, Mou L C, Li W Y, Wright J, Li X C, Li X L, Zhu X X, Wang J, Yu L and Gong P. 2018. Long-term annual mapping of four cities on different continents by applying a deep information learning method to landsat data. *Remote Sensing*, 10(3): #471 [DOI: 10.3390/rs10030471]
- Lyu Z Y, Shi W Z, Zhou X C and Benediktsson J A. 2017. Semi-automatic system for land cover change detection using bi-temporal remote sensing images. *Remote Sensing*, 9(11): #1112 [DOI: 10.3390/rs9111112]
- Mandanici E and Bitelli G. 2015. Multi-image and multi-sensor change detection for long-term monitoring of arid environments with Landsat series. *Remote Sensing*, 7(10): 14019-14038 [DOI: 10.3390/rs71014019]
- Misbari S and Hashim M. 2016. Change detection of submerged seagrass biomass in shallow coastal water. *Remote Sensing*, 8(3): #200 [DOI: 10.3390/rs8030200]
- Nielsen A A. 2007. The regularized iteratively reweighted MAD method for change detection in multi- and hyper-spectral data. *IEEE Transactions on Image Processing*, 16(2): 463-478 [DOI: 10.1109/TIP.2006.888195]
- Nielsen A A and Müller A. 2003. Change detection by the MAD method in hyperspectral image data//*Proceedings of the 3rd EARSeL Workshop on Imaging Spectroscopy*. Hersching, Germany: RASeL: 115-116
- Nourani V, Roushangar K and Andalib G. 2018. An inverse method for watershed change detection using hybrid conceptual and artificial intelligence approaches. *Journal of Hydrology*, 562: 371-384 [DOI: 10.1016/j.jhydrol.2018.05.018]
- Ortiz-Rivera V, Vélez-Reyes M and Roysam B. 2006. Change detection in hyperspectral imagery using temporal principal components//*Proceedings of SPIE 6233, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XII*. Orlando, USA: SPIE: #623312 [DOI: 10.1117/12.667961]
- Qu J H, Xu Y S, Dong W Q, Li Y S and Du Q. 2021. Dual-branch difference amplification graph convolutional network for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5519912 [DOI: 10.1109/TGRS.2021.3135567]
- Shafique A, Seydi S T, Alipour-Fard T, Cao G and Yang D. 2023. SSViT-HCD: a spatial-spectral convolutional vision Transformer for hyperspectral change detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 6487-6504 [DOI: 10.1109/JSTARS.2023.3251646]
- Shi C J, Zhang Z J, Zhang W C, Zhang C R and Xu Q. 2022. Learning multiscale temporal-spatial-spectral features via a multipath convolutional LSTM neural network for change detection with hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5529816 [DOI: 10.1109/TGRS.2022.3176642]
- 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]
- Song R, Ni W, Cheng W and Wang X. 2022. CSANet: cross-temporal interaction symmetric attention network for hyperspectral image change detection. *IEEE Geoscience and Remote Sensing Letters*, 19: #6010105 [DOI: 10.1109/LGRS.2022.3179134]
- Sublime J and Kalinicheva E. 2019. Automatic post-disaster damage mapping using deep-learning techniques for change detection: case study of the Tohoku tsunami. *Remote Sensing*, 11(9): #1123 [DOI: 10.3390/rs11091123]
- Sun Y L, Lei L, Liu L and Kuang G Y. 2023. Structural regression fusion for unsupervised multimodal change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #4504018 [DOI: 10.1109/TGRS.2023.3294884]
- Vongsy K and Mendenhall M J. 2016. Integrating spatial & spectral information for change detection in hyperspectral imagery//*Proceedings of the 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*. Los Angeles, USA: IEEE: 1-5 [DOI: 10.1109/WHISPERS.2016.8071703]
- Wang L F, Wang L G, Wang Q M and Atkinson P M. 2021. SSA-SiamNet: spectral-spatial-wise attention-based Siamese network for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5510018 [DOI: 10.1109/TGRS.2021.3095899]
- Wang L G, Wang L F, Wang Q M and Bruzzone L. 2022a. 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]
- Wang X H, Ni W H, Feng Y N and Song L Y. 2023. AgF²Net: attention-guided feature fusion network for multitemporal hyperspectral image change detection. *IEEE Geoscience and Remote Sensing Letters*, 20: #5507805 [DOI: 10.1109/LGRS.2023.3302469]
- Wang Y H, Hong D F, Sha J J, Gao L R, Liu L, Zhang Y G and Rong X H. 2022b. Spectral-spatial-temporal Transformers for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5536814 [DOI: 10.1109/TGRS.2022.3203075]
- Wu C, Du B and Zhang L P. 2013. A subspace-based change detection method for hyperspectral images. *IEEE Journal of Selected Topics*

- in *Applied Earth Observations and Remote Sensing*, 6(2): 815-830 [DOI: 10.1109/JSTARS.2013.2241396]
- Xiao K W, Sun Y L and Lei L. 2022. Change alignment-based image transformation for unsupervised heterogeneous change detection. *Remote Sensing*, 14(21): #5622 [DOI: 10.3390/rs14215622]
- Yang Y F, Qu J H, Xiao S, Dong W Q, Li Y S and Du Q. 2022. A deep multiscale pyramid network enhanced with spatial-spectral residual attention for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5525513 [DOI: 10.1109/TGRS.2022.3161386]
- Ye Z, Bai L and He M Y. 2021. Review of spatial-spectral feature extraction for hyperspectral image. *Journal of Image and Graphics*, 26(8): 1737-1763 (叶珍, 白璘, 何明一. 2021. 高光谱图像空谱特征提取综述. *中国图象图形学报*, 26(8): 1737-1763) [DOI: 10.11834/jig.210198]
- Zhan T M, Song B, Xu Y, Wan M H, Wang X, Yang G W and Wu Z B. 2021. SSCNN-S: a spectral-spatial convolution neural network with Siamese architecture for change detection. *Remote Sensing*, 13(5): #895 [DOI: 10.3390/rs13050895]
- Zhang X R, Tian S L, Wang G C, Tang X, Feng J and Jiao L C. 2023. CAST: a CAscade spectral-aware Transformer for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*. 61: #5520714 [DOI: 10.1109/TGRS. 2023. 3304681]
- 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]
- Zhou Z J, Ma L, Fu T Y, Zhang G, Yao M R and Li M C. 2018. Change detection in coral reef environment using high-resolution images: comparison of object-based and pixel-based paradigms. *ISPRS International Journal of Geo-Information*, 7(11): #441 [DOI: 10.3390/ijgi7110441]

作者简介

丁晨,男,副教授,主要研究方向为图像处理、机器学习与模式识别。E-mail: dingchen@xupt.edu.cn

张艳宁,通信作者,女,教授,主要研究方向为遥感图像分析、计算机视觉和模式识别。E-mail: ynzhang@nwpu.edu.cn

陈静怡,女,硕士研究生,主要研究方向为图像处理和遥感图像变化检测。E-mail: chenjingyi@stu.xupt.edu.cn

郑萌萌,女,硕士研究生,主要研究方向为图像处理、机器学习和主动学习。E-mail: zmm@stu.xupt.edu.cn

张磊,男,教授,主要研究方向为图像处理、小样本学习和视频分析。E-mail: nwpuzhanglei@nwpu.edu.cn

魏巍,男,教授,主要研究方向为图像质量提升、机器学习和模式识别。E-mail: weiweinwp@nwpu.edu.cn