

doi: 10.6046/zrzyyg.2021351
引用格式: 秦乐,何鹏,马玉忠,等. 基于时空谱特征的遥感影像时间序列变化检测[J]. 自然资源遥感,2022,34(4):105-112.
(Qin L,He P,Ma Y Z,et al. Change detection of satellite time series images based on spatial-temporal-spectral features[J]. Remote Sensing for Natural Resources,2022,34(4):105-112.)

基于时空谱特征的遥感影像时间序列变化检测

秦 乐¹, 何 鹏², 马玉忠³, 刘建强⁴, 杨 彬¹

(1. 湖南大学电气与信息工程学院,长沙 410082; 2. 南华大学机械工程学院,衡阳 421000;
3. 山东省国土测绘院,济南 250014; 4. 国家卫星海洋应用中心,北京 100081)

摘要:相较于常见的双时相遥感影像,时间序列遥感影像包含更丰富的地表信息,能够缓解“异物同谱”、“同物异谱”的影响,因而在变化检测中具有重要作用。但是目前时间序列遥感影像变化检测方法大多基于像素展开,忽略了像素和周围环境的空间关系,导致变化检测结果“噪声”现象明显。基于此,提出了一种基于时空谱特征的时间序列遥感变化检测算法(change detection based on spatial-temporal-spectral features, CDSTS)。首先,利用灰度共生矩阵和局部统计计算方法,从 Landsat 时间序列遥感影像中提取每个像素点的时间、空间(纹理和统计)和光谱特征;其次,通过每个像素在不同波段上的时间序列表现规律,自动筛选出时序特征异常点,并与连续变化检测和分类法(continuous change detection and classification, CCDC)检测结果融合获取高精度变化/未变化训练样本点;最后,利用上述样本点及其对应的时空谱特征训练支持向量机分类器,并基于该分类器对全图进行分类。结果表明,CDSTS 算法在变化区域检测精准度方面明显优于常用的时间序列变化检测算法 CCDC 和土地扰动连续监测方法(continuous monitoring of land disturbance, COLD),总体精度提升了 4.8~11.7 百分点。

关键词: Landsat; 时间序列; 变化检测; 纹理特征

中图法分类号: TP 79 **文献标志码:** A **文章编号:** 2097-034X(2022)04-0105-08

0 引言

地球表面由于植被物候、土地管理、气候变化、森林砍伐、城市化等诸多因素的影响总是在不断发生变化。变化检测是通过对地物或现象进行多次观测从而识别其状态变化的过程^[1]。它可以提供地球表面的变化信息,对于土地覆盖监测、自然灾害损害评估和城市扩张监管等应用至关重要^[2-6]。

各国学者从不同的角度研究了大量的变化检测算法和理论模型。从检测变化的本质策略上可以将这些算法分为 2 大类:双时相影像变化检测和时间序列影像变化检测。双时相变化检测使用 2 幅影像检测前后 2 个时刻地面的变化,变化向量分析法、主成分分析法以及深度学习等变化检测算法都采用了双时相影像^[7-10]。随着神经网络在遥感领域的不断发展,很多基于深度学习的变化检测方法被用来处理遥感影像数据之间的相关性特征^[11-12],但这种

方法大多是双时相的变化检测,很难对长时间序列的影像进行处理。在多云或多雨的地区,可能需要数年时间才能收集到理想的 2 幅影像,所以双时相变化检测的方法具有明显的局限性。而时间序列变化检测通过连续的时间序列影像分析地表随时间的变化规律,即使某些影像中的部分区域被云和云阴影覆盖也可以通过时间序列进行变化检测,而且时间序列遥感影像包含更丰富的地表信息,能够减少“异物同谱”、“同物异谱”的影响。随着遥感卫星历史数据的不断普及,遥感影像时间序列的变化检测受到越来越多的关注^[13-17]。

针对时间序列变化检测在各领域的应用需求,时间序列变化检测方法正在不断发展^[18-19]。比如 Kennedy 等^[20]通过逐个像素提取植被表面变化的多时相光谱轨迹,并假设变化是以不同的速率连续发生的,提出基于 Landsat 影像的植被表面变化趋势的检测方法;Huang 等^[21]使用一种植被变化跟踪器方法来检测森林变化,它将每个像素的反射率归一

收稿日期: 2021-10-21; 修订日期: 2021-12-02

基金项目: 国家自然科学基金项目“基于偏振反射与光谱不变量的植被氮含量遥感反演”(编号: 41801227)和湖南省自然科学基金项目“基于随机辐射传输理论的农作物叶面积指数和叶绿素含量遥感反演”(编号: 2019JJ50047)共同资助。

第一作者: 秦 乐(1997-),男,硕士研究生,研究方向为遥感影像时间序列的变化检测。Email: hnuqinle@hnu.edu.cn。

通信作者: 杨 彬(1989-),男,博士,副教授,研究方向为遥感图像处理。Email: binyang@hnu.edu.cn。

化为概率指数,然后通过确定阈值来检测植被变化; Verbesselt 等^[22]提出了一种季节趋势的断点检测算法,研究每个像素的变化趋势,并基于这种变化趋势在新收集的影像中检测变化; Zhu 等^[23]将变化检测从植被扩展到其他地表,并提出了一种使用所有可用的 Landsat 影像的连续变化探测和分类法(continuous change detection and classification,CCDC),利用同一区域积累的 Landsat 历史影像为每个像素拟合一条曲线,通过比较模型预测值来检测变化。CCDC 成为从遥感卫星时间序列中检测变化的最受欢迎的方法之一,并被选为美国地质勘探局进行变化检测的官方算法。在此基础上 Zhu 等^[24]又提出一种利用不同输入、不同系数个数的时间序列模型对土地扰动进行连续监测的方法(continuous monitoring of land disturbance,COLD),它可以对目标区域的地表变化进行实时监测。

目前现有的基于遥感影像时间序列的变化检测主要存在以下问题:①大多数变化检测方法是基于像素的方法,其假设像素之间是独立的,却忽略像素和周围环境的空间关系^[25-26],导致变化检测结果“噪声”现象明显;②在变化检测中通常需要“告诉”计算机什么样的特征变化是真正的变化,即训练过程需要标记出变化和未变化的像素,这个标记过程如果可以通过算法自动完成,就可以节省大量准备训练样本的时间。

为了解决上述问题,本文提出了一种基于时空谱特征的时间序列遥感变化检测算法(change detection based on spatial-temporal-spectral features,CDSTS)。首先,从 Landsat 影像时间序列中提取光谱、纹理和统计特征,并将它们堆叠处理获得高维特征矩阵;其次,设计一种无监督的方法自动生成训练样本及标签;利用支持向量机对训练样本点的时空谱特征进行训练并对全图进行预测,进而得到变化检测结果;最后,在中国 5 个不同类型的地区进行变化测试并与其他方法对比进行精度评估。

1 研究区和数据源

为了验证 CDSTS 在不同场景区域中的应用效果,在常德(CD)、岳阳(YY)、福清(FQ)、雄安(XA)和防城港(FCG)这 5 个中国城市中各选择 120 km²左右的区域作为研究对象。选择这些场景进行研究主要有 2 个原因:第一,这些区域包含城郊、湿地、海岸线、植被和城市等场景,有助于验证 CDSTS 算法对不同土地类型变化检测的适用性;第二,由于城市化的快速发展和大规模基础设施建设,这些研究区域在 2013—2020 年间发生了明显的土地类型变化。

本文使用的多时相遥感影像来自 Landsat 卫星影像 Level-2 级 Collection 1 数据,其中 Collection 1 由 Tier 1,Tier 2 以及 Real-Time 这 3 层组成。Tier 1 由最高质量的 Landsat 数据组成,所以最适合用于时间序列的变化检测。文章收集使用了 2013—2020 年间 Landsat7 和 Landsat8 卫星所有可用的遥感影像作为研究对象,每幅遥感影像包含 7 个光谱波段:蓝光波段、绿光波段、红光波段、近红外波段(near infrared,NIR)、短波红外波段 1 和波段 2(short wave infrared,SWIR)和热红外波段(thermal infrared,TIR)。

图 1 是 2013—2020 年各个研究区域使用的影像数量,CD,YY,FQ,XA 和 FCG 这 5 个场景使用的影像总数分别是 87,109,141,151 和 83。




图 1 各研究区域每年使用的影像数量
Fig.1 Number of used images for each study area in each year

2 研究方法

本文提出的 CDSTS 算法主要包括以下 3 个步骤:①特征提取;②获取训练样本和变化检测;③精度评估。其流程如图 2 所示。




图 2 CDSTS 算法流程
Fig.2 Workflow of the CDSTS

2.1 特征提取

特征提取的目的是构建一个高维的叠加特征矩阵,该矩阵由 Landsat 影像的时空谱特征组成。提取的特征主要包括光谱特征、纹理特征、统计特征和时

间特征。纹理特征和统计特征考虑了像素和周围环境的空间关系,可以有效提高变化检测结果的准确性。如图 3 所示,虽然图 3(a)中红点位置像素的光谱信息在 2017 年 12 月 8 日(图 3(b)中红色竖线位

置)没有发生明显变化,但是地表的空间纹理却在 2017 年 12 月 8 日(图 3(c)和图 3(d)中红色竖线位置)发生变化,这种变化可以在空间特征中清楚显示。




图 3 样本像素的归一化光谱、纹理和统计特征
Fig.3 Normalized spectral, textural and statistical features for a sample pixel

1) 光谱特征。地表的光谱反射率会随土地类型的改变而出现变化,这是判断地表是否发生变化的重要依据。在本研究中,Landsat 影像的光谱特征 S_p 公式为:

$$S_p = \{\rho_b, \rho_g, \rho_r, \rho_n, \rho_{s1}, \rho_{s2}, t_T\}, \quad (1)$$

式中: $\rho_b, \rho_g, \rho_r, \rho_n, \rho_{s1}, \rho_{s2}$ 分别为蓝光波段、绿光波段、红光波段、近红外波段 NIR、短波红外波段 SWIR 1 和 SWIR 2 的地表反射率; t_T 为热红外波段的地表温度。值得注意的是,大部分的时序变化检测方法(如 CCDC 和 COLD)仅使用影像中的光谱特征 S_p 进行变化检测。

2) 纹理特征。纹理特征可以用来区分不同的土地覆盖类型,目前它已被广泛用于检测土地覆盖类型的算法中。灰度共生矩阵(gray-level co-occurrence matrix, GLCM)作为一种能有效从遥感影像中提取纹理特征的方法而被广泛使用。纹理特征 T_e 的公式为:

$$T_e = \{G_1, G_2, G_3, G_4, G_5, G_6, G_7, G_8\}, \quad (2)$$

式中 $G_1 \sim G_8$ 分别为灰度共生矩阵 GLCM 的 8 种特征,即均值、方差、对比度、相异度、熵、二阶矩、同质性和集群阴影。在 4 个方向上($0^\circ, 45^\circ, 90^\circ$ 和 135°)分别计算 GLCM 的特征值并求取平均值。

3) 统计特征。土地类型的变化检测通常包括局部区域的变化细节。在本研究中,利用滑动窗口的方式计算统计特征(即均值和方差),来描述遥感

影像局部区域的变化细节。统计特征 S_t 的公式为:

$$S_t = \{Mean, Variance\}, \quad (3)$$

$$Mean = \frac{\sum_{i=1, j=1}^n V(i, j)}{n^2}, \quad (4)$$

$$Variance = \frac{\sum_{i=1, j=1}^n [V(i, j) - Mean]^2}{n^2}, \quad (5)$$

式中: n 为窗口的大小,本文中 n 设置为 3; $V(i, j)$ 为移动窗口第 i 行和第 j 列所对应的光谱值。需要注意的是,纹理特征值中的均值和方差是使用 GLCM 的特征值计算得到的,而统计特征中的均值和方差是直接使用地表反射率或温度计算得到的。

4) 时间特征。通过光谱、纹理和统计特征的堆叠可获得第 k 幅 Landsat 影像的时间特征,即

$$F_k = \{S_p, T_e, S_t\}. \quad (6)$$

将所有遥感影像的时间特征 F_k 按照时间顺序堆叠到一起,最终就能得到时空谱特征,即

$$F = \{F_1, F_2, \dots, F_M\}, \quad (7)$$

式中 M 为 Landsat 影像的数量。为了减少特征值大小不同导致的影响,将特征值进行归一化处理,即

$$PV' = \frac{PV - PV_{\min}}{PV_{\max} - PV_{\min}}, \quad (8)$$

式中: PV 和 PV' 分别为归一化前后每个特征的值;

$PV_{\max}$ 和 $PV_{\min}$ 分别为归一化前每个特征值对应的最大值和最小值。

2.2 获取训练样本和变化预测

研究使用的 CDSTS 算法中设计了一种无监督的方法自动生成支持向量机训练所必需的训练样本及标签。无监督获取训练样本的方式如下：

1) CCDC 先验知识获取。尽管 CCDC 没有利用像素间的空间信息,但其变化检测结果可以作为选择训练样本时的先验知识。CCDC 算法为每个像素拟合一条曲线,通过比较模型预测值来检测变化,最终将像素分为变化像素和未变化像素,CCDC 模型的公式为:

$$\rho(i, x) = a_{0,i} + a_{1,i} \cos\left(\frac{2\pi x}{365}\right) + b_{1,i} \sin\left(\frac{2\pi x}{365}\right) + c_{1,i}, \quad (9)$$

式中: $\rho(i, x)$ 为波段值; x 为儒略日; $a_{0,i}$ 为第 i 个 Landsat 波段的总体值的系数; $a_{1,i}$ 和 $b_{1,i}$ 为第 i 个波段的年内变化系数; $c_{1,i}$ 为第 i 个波段的年际变化系数。如果预测值和实际观测值之间的差异连续 3 次超过阈值时,会被认为是发生了地表变化。

2) 变化训练样本提取。变化训练样本的提取是将每个像素的所有观测值全部用于拟合式(9),如果没有发生变化,那么通过拟合得到的预测值将接近测量值。此时,观测值与预测值之间的均方根误差(root mean square error, RMSE)很小。相反,如果发生变化,二者之间的 RMSE 会很高。因此, RMSE 可以被用作区分变化的和未变化像素的指标。训练样本中变化样本的获得方式具体如下:对每个像素在不同波段上的时间序列进行拟合并分别计算 RMSE,利用大津阈值算法分别对不同波段得到的 RMSE 结果进行阈值分割得到各波段的预检测结果图 C ,如果某个像素在 7 个波段中有 N 次被检测为变化点,则它被认定为发生了变化的像素,通过这种投票机制获得变化图 P_{rc} 。最后选取的变化样本 P_c 是通 CCDC 得到的结果图 P_{cc} 和 RMSE 阈值法处理得到的 P_{rc} 取交集得到的,即

$$P_c = P_{cc} \cap P_{rc}。 \quad (10)$$

3) 未变化的训练样本提取。未变化训练样本的获得方式是从各个波段得到的预检测结果图 C 中找出未变化的像素。如果某个像素在 7 个波段中全部被检测为未变化点,则被认定为未发生变化的像素。通过这种投票机制获得未变化图 P_u 。最终选取的不变样本 $\widetilde{P}_u$ 是通过 CCDC 算法得到的未变

化点 P_{cu} 和 RMSE 阈值处理法得到的不变点 P_u 取交集得到的,即

$$\widetilde{P}_u = P_{cu} \cap P_u。 \quad (11)$$

由于 CCDC 算法是根据像素的时间序列分别得到每个像素的变化结果,因此像素之间相互独立,这就会导致结果中出现很多零散的点。比如,在大片的变化区域内存在一些零散的不变点,从像素之间的空间关系上看这些零散的不变点大概率是检测错误的点,实际上这些像素点发生了地表变化只是由于算法的原因没有被检测出来。为了抑制这些零散错误点的影响,在 $\widetilde{P}_u$ 中除去少于 7 个像素的未变化区域,以获得准确率更高的未变化样本 P_u 。

从上述预检测方法中生成训练样本点及标签,变化样本点的标签为 1,未变化样本点的标签为 0。本文使用包含 radial basis kernel 函数的 LIBSVM 库,通过十折交叉验证的方式调整自由变量。训练样本的数据格式为二维矩阵,其中第一个维度为训练样本的数量,第二个维度是叠加后的时空谱特征数量,即光谱、纹理和统计特征之和与时间序列长度的乘积。通过支持向量机对这些训练样本数据进行训练,并利用生成的模型对全图进行预测,进而得到变化检测结果。

2.3 精度评估

精度评估需要准备可用于参考的地表真值图与得到的变化检测结果。本研究基于 Landsat 影像和谷歌地球的高分辨率历史影像手动标记变化和未变化的像素。每个研究区域均选择了 520 个像素作为参考点,其中 260 个像素发生了土地变化,260 个像素在整个 2013—2020 年期间未发生变化。CCDC 和 COLD 算法被认为是时序变化检测的算法中最先进的 2 种算法,将 CDSTS 算法与这 2 种算法进行了精度对比。本文使用精确率(precision)、召回率(recall)、F1 分数和总体精度(overall accuracy, OA)等精度评估指标。4 种评估指标计算公式分别为:

$$precision = \frac{TP}{TP + FP} \times 100\% , \quad (12)$$

$$recall = \frac{TP}{TP + FN} \times 100\% , \quad (13)$$

$$F1 = \frac{2precision \ recall}{precision + recall} \times 100\% , \quad (14)$$

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% , \quad (15)$$

式中: TP 为被判定为正样本的正样本数量; TN 为

被判定为负样本的负样本数量； FP 为被判定为正样本的负样本数量； FN 为被判定为负样本的正样本数量。

3 结果分析

3.1 定性分析

表 1 为 5 个研究区域的变化检测结果的对比结

果。通常情况下,如果变化区域较大(例如城市化),那么 CCDC 或 COLD 算法容易出现许多类似“噪声”的错误检测结果,因为它忽略了变化像素与周围环境之间的空间关系。相比之下,CDSTS 算法的检测结果具有明显的纹理特征,更加符合真实情况。表 2 为表 1 中红色方框区域的细节对比。通过对比表 2 中 3 种算法的变化检测细节,可以明显看出 CDSTS 算法结果优于 CCDC 和 COLD 算法。

表 1 不同方法的变化检测结果
Tab.1 Change detection results for different approaches
















区域	2013 年影像	2020 年影像	CCDC 结果	COLD 结果	CDSTS 结果
CD					
YY					
FQ					
XA					
FCG					

表 2 不同方法的变化检测结果细节对比
Tab.2 Comparison of the change detection results of different methods in details

区域	2013 年影像	2020 年影像	CCDC 结果	COLD 结果	CDSTS 结果
CD					
YY					
FQ					

(续表)

区域	2013 年影像	2020 年影像	CCDC 结果	COLD 结果	CDSTS 结果
XA					
FCG					

3.2 定量比较

利用 CCDC, COLD 和 CDSTS 算法分别在 5 个研究区域 (CD, YY, FQ, XA 和 FCG) 得到变化检测结果, 通过 *precision*, *recall*, *OA* 和 *F1* 分数等 4 种评价指标对不同算法进行精度评估。如表 3 所示, 在 5 个研究区域中本文的 CDSTS 算法在各种评价指标

中表现最好。以 *OA* 为例, 与 CCDC 算法相比, CDSTS 算法在 5 个研究区域的 *OA* 分别提高了 7.6, 11.1, 5.0, 8.8 和 11.5 百分点; 与 COLD 算法相比, CDSTS 算法在 5 个研究区域的 *OA* 分别提高了 8.8, 11.7, 4.8, 9.6 和 4.8 百分点。

表 3 不同方法的精度评估
Tab. 3 Accuracy assessment using different methods (%)

场景	评价指标	CCDC		COLD		CDSTS	
		未变化	变化	未变化	变化	未变化	变化
CD	<i>precision</i>	84.73	92.44	82.46	93.02	97.12	94.55
	<i>recall</i>	93.20	83.20	94.00	80.00	94.40	97.20
	<i>F1</i>	88.76	87.58	87.85	86.02	95.74	95.86
	<i>OA</i>	88.20		87.00		95.80	
YY	<i>precision</i>	80.95	84.21	77.30	88.43	92.51	94.86
	<i>recall</i>	85.00	80.00	90.38	73.46	95.00	92.31
	<i>F1</i>	82.93	82.05	83.33	80.25	93.74	93.57
	<i>OA</i>	82.50		81.92		93.65	
FQ	<i>precision</i>	94.66	79.30	90.39	81.79	92.68	88.32
	<i>recall</i>	75.00	95.77	79.62	91.54	87.69	93.08
	<i>F1</i>	83.69	86.76	84.66	86.39	90.12	90.64
	<i>OA</i>	85.38		85.58		90.38	
XA	<i>precision</i>	82.45	78.91	76.27	84.44	84.28	96.38
	<i>recall</i>	77.69	83.46	86.54	73.08	96.92	81.92
	<i>F1</i>	80.00	81.12	81.08	78.35	90.16	88.57
	<i>OA</i>	80.58		79.81		89.42	
FCG	<i>precision</i>	88.65	78.46	94.94	85.15	97.61	91.35
	<i>recall</i>	75.19	90.37	83.33	95.56	90.74	97.78
	<i>F1</i>	81.36	83.99	88.76	90.05	94.05	94.45
	<i>OA</i>	82.78		89.44		94.26	

3.3 不同参数的影响

本研究中投票机制的阈值 N 和计算纹理与统计特征所用的窗口尺寸会对实验结果产生重要影响。在自动选择训练样本时, 如果采取的投票机制的阈值 $N(1 < N < 7)$ 被设置为 3, 则表示一个像素在 7 个波段中至少有 3 次被检测为变化点才被认为是变化像素。因此, N 值越大, 样本的选择就越严格, 训练样本的数量就越少, 这会影响最终的变化检测精度。图 4 是 5 个研究区域的 OA 随 N 值变化的曲线图, 从图 4 中可以看出 OA 随着 N 值的增大而逐渐减小。因此, 在本文中 N 被设置为 1; 此外, 为了确定计算纹理特征和统计特征的最佳窗口大小, 在所有研究区域的 Landsat 影像上测试了 5 个窗口大




图 4 使用不同阈值的变化检测的总体精度
Fig. 4 Overall accuracy of change detection using different thresholds

小(3,5,7,9 和 11)。结果表明,不同窗口大小下检测结果的准确性没有显著差异。但由于 Landsat 影像的空间分辨率为 30 m,窗口过大会使得纹理和统计特征难以区分,因此本文将窗口尺寸设置为 3。

4 结论与讨论

本文提出了一种基于遥感影像时间序列的新变化检测算法(CDSTS)。其主要贡献在于:在变化检测中考虑了空间信息(纹理和统计特征),并且可以自动生成用于训练的变化和未变化的样本。利用支持向量机对包含时空谱特征的训练样本进行预测得到变化检测结果。在中国的 5 个研究区域与广泛使用的 CCDC 和 COLD 时间序列变化检测算法进行精度对比,结果显示 CDSTS 算法在各项评价指标上均有着良好表现。

虽然准确度评估显示了 CDSTS 算法的良好性能,但它也存在局限性。首先,CDSTS 算法在预检测部分以 CCDC 算法的结果作为先验知识,因此 CDSTS 算法的计算量很大并且需要存储大量 Landsat 影像时间序列;其次,与 CCDC 和 COLD 不同,CDSTS 算法只能识别变化,不能识别土地变化类型和发生变化的时间,解决这些问题需要对算法进行更加深入的研究。

参考文献(References):

- [1] Singh A. Review article digital change detection techniques using remotely - sensed data[J]. International Journal of Remote Sensing, 1989, 10(6): 989 - 1003.
- [2] Silveira E M O, Bueno I T, Acerbi - Junior F W, et al. Using spatial features to reduce the impact of seasonality for detecting tropical forest changes from Landsat time series[J]. Remote Sensing, 2018, 10(6): 808.
- [3] Gómez C, White J C, Wulder M A. Optical remotely sensed time series data for land cover classification: A review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 116: 55 - 72.
- [4] Hussain M, Chen D, Cheng A, et al. Change detection from remotely sensed images: From pixel - based to object - based approaches[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2013, 80: 91 - 106.
- [5] Roy D P, Wulder M A, Loveland T R, et al. Landsat8: Science and product vision for terrestrial global change research[J]. Remote Sensing of Environment, 2014, 145: 154 - 172.
- [6] Zhu Z, Woodcock C E, Holden C, et al. Generating synthetic Landsat images based on all available Landsat data: Predicting Landsat surface reflectance at any given time[J]. Remote Sensing of Environment, 2015, 162: 67 - 83.
- [7] 张良培, 武 辰. 多时相遥感影像变化检测的现状与展望[J]. 测绘学报, 2017, 46(10): 1447 - 1459.
- [8] 王志有, 李 欢, 刘自增, 等. 基于深度学习算法的卫星影像变化监测[J]. 计算机系统应用, 2020, 29(1): 40 - 48.
- [9] Wang Z Y, Li H, Liu Z Z, et al. Satellite image change monitoring based on deep learning algorithm[J]. Computer System Applications, 2020, 29(1): 40 - 48.
- [10] Celik T. Unsupervised change detection in satellite images using principal component analysis and K - means clustering[J]. IEEE Geoscience and Remote Sensing Letters, 2009, 6(4): 772 - 776.
- [11] Tewkesbury A P, Comber A J, Tate N J, et al. A critical synthesis of remotely sensed optical image change detection techniques[J]. Remote Sensing of Environment, 2015, 160: 1 - 14.
- [12] Gong M G, Zhan T, Zhang P Z, et al. Superpixel - based difference representation learning for change detection in multispectral remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(5): 2658 - 2673.
- [13] Zhang P Z, Gong M G, Su L Z, et al. Change detection based on deep feature representation and mapping transformation for multi - spatial - resolution remote sensing images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 116: 24 - 41.
- [14] Woodcock C E, Loveland T R, Herold M, et al. Transitioning from change detection to monitoring with remote sensing: A paradigm shift[J]. Remote Sensing of Environment, 2020, 238: 111558.
- [15] Hamunyela E, Brandt P, Shirima D, et al. Space - time detection of deforestation, forest degradation and regeneration in montane forests of eastern Tanzania[J]. International Journal of Applied Earth Observation and Geoinformation, 2020, 88: 102063.
- [16] Liu C, Zhang Q, Luo H, et al. An efficient approach to capture continuous impervious surface dynamics using spatial - temporal rules and dense Landsat time series stacks[J]. Remote Sensing of Environment, 2019, 229: 114 - 132.
- [17] Wang Z H, Yao W Y, Tang Q H, et al. Continuous change detection of forest/grassland and cropland in the Loess Plateau of China using all available Landsat data[J]. Remote Sensing, 2018, 10(11): 1775.
- [18] Xiao P F, Zhang X L, Wang D G, et al. Change detection of built - up land: A framework of combining pixel - based detection and object - based recognition[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 119: 402 - 414.
- [19] 杜培军, 柳思聪. 融合多特征的遥感影像变化检测[J]. 遥感学报, 2012, 16(4): 663 - 677.
- [20] Du P J, Liu S C. Remote sensing image change detection based on multi - feature fusion[J]. Journal of Remote Sensing, 2012, 16(4): 663 - 677.
- [21] Zhu Z. Change detection using landsat time series: A review offrequencies, preprocessing, algorithms, and applications[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 130: 370 - 384.
- [22] Kennedy R E, Yang Z, Cohen W B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. Land-Trendr - Temporal segmentation algorithms[J]. Remote Sensing of Environment, 2010, 114(12): 2897 - 2910.
- [23] Huang C, Goward S N, Masek J G, et al. An automated approach for reconstructing recent forest disturbance history using dense

Landsat time series stacks[J]. Remote Sensing of Environment, 2010,114(1):183–198.

[22] Verbesselt J,Zeileis A,Herold M. Near real – time disturbance detection using satellite image time series[J]. Remote Sensing of Environment,2012,123:98–108.

[23] Zhu Z,Woodcock C E. Continuous change detection and classification of land cover using all available Landsat data[J]. Remote Sensing of Environment,2013,144(1):152–171.

[24] Zhu Z,Zhang J,Yang Z,et al. Continuous monitoring of land disturbance based on Landsat time series[J]. Remote Sensing of Environment,2020,238:111116.

[25] Zhang H,Gong M G,Zhang P Z,et al. Feature – level change detection using deep representation and feature change analysis for multispectral imagery[J]. IEEE Geoscience and Remote Sensing Letters,2016,13(11):1666–1670.

[26] Chen G,Hay G J,Carvalho L M T,et al. Object – based change detection[J]. International Journal of Remote Sensing, 2012, 33(14):4434–4457.

Change detection of satellite time series images based on spatial – temporal – spectral features

QIN Le¹, HE Peng², MA Yuzhong³, LIU Jianqiang⁴, YANG Bin¹

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China; 2. School of Mechanical Engineering, University of South China, Hengyang 421000, China; 3. Shandong Provincial Institute of Land Surveying and Mapping, Jinan 250014, China; 4. Key Laboratory of Space Ocean Remote Sensing and Application, Ministry of Natural Resources, Beijing 100081, China)

Abstract: Compared with common dual – temporal satellite images, satellite time series images contain richer surface information and can alleviate the impact of foreign objects with the same spectrum and the same object with different spectra. Therefore, they play an important role in change detection. However, the change detection methods for satellite time series images are mostly based on pixels and ignore the spatial relationship between pixels and their surroundings. This causes noise in the change detection result. Accordingly, this study proposed a method of change detection based on spatial – temporal – spectral features(CDSTS) for satellite time series images. First, the temporal, spatial (textural and statistical), and spectral features of each pixel were extracted from Landsat time series images using a gray – level co – occurrence matrix and local statistical calculation methods. Then, anomalies of time series features were automatically screened according to the time series performance regularity of each pixel in different bands. These anomalies were then fused with the detection results of the continuous change detection and classification method (CCDC) to obtain high – precision changed/unchanged training sample points. Finally, the SVM classifier was trained using the training sample points and their corresponding spatial – temporal – spectral features for full graph classification. The results show that the CDSTS algorithm significantly outperforms the commonly used time series change detection algorithms CCDC and COLD (continuous monitoring of land disturbance) in terms of change detection precision, with the overall precision improved by 4.8 to 11.7 percentage points.

Keywords: Landsat; time series; change detection; textural feature

(责任编辑: 张 仙)