

遥感时间序列影像变化检测研究进展

赵忠明¹, 孟瑜¹, 岳安志¹, 黄青青¹, 孔赟珑^{1,2}, 袁媛^{1,2}, 刘晓奕^{1,2},
林蕾^{1,2}, 张蒙蒙³

1. 中国科学院遥感与数字地球研究所, 北京 100101;

2. 中国科学院大学, 北京 100049;

3. 北京化工大学 信息科学与技术学院, 北京 100029

摘要: 同一区域、不同时期大量历史数据的积累, 以及同一区域能够方便地获取高时间分辨率遥感数据, 使遥感时间序列影像变化检测成为近年来遥感技术与应用的研究热点。本文系统总结和评述了当前遥感时间序列影像变化检测的相关研究进展和应用状况, 在阐明遥感时间序列分析的意义, 以及时间序列影像在变化检测中的优势的基础上, 从非遥感领域时间序列变化检测方法出发, 针对遥感时间序列影像变化检测的需求, 明确和归纳了遥感时间序列变化检测的问题与类型, 并对当前最新研究进行了综述, 总结了各种方法的优点与不足, 重点介绍了基于经验模态分解的遥感时间序列影像异常信息检测方法和基于隐马尔可夫模型的土地利用/覆盖变化检测方法, 以期能够为相关研究提供参考。最后总结了该研究领域的发展趋势和存在问题, 并对今后的研究工作和未来发展方向进行了展望。

关键词: 时间序列, 变化检测, 异常检测, 土地利用/覆盖, 经验模态分解, 隐马尔可夫模型

中图分类号: TP751.1 **文献标志码:** A

引用格式: 赵忠明, 孟瑜, 岳安志, 黄青青, 孔赟珑, 袁媛, 刘晓奕, 林蕾, 张蒙蒙. 2016. 遥感时间序列影像变化检测研究进展. 遥感学报, 20(5): 1110-1125

Zhao Z M, Meng Y, Yue A Z, Huang Q Q, Kong Y L, Yuan Y, Liu X Y, Lin L and Zhang M M. 2016. Review of remotely sensed time series data for change detection. Journal of Remote Sensing, 20(5): 1110-1125 [DOI:10.11834/jrs.20166170]

1 引言

卫星遥感对地观测具有重访性特点, 随着遥感技术几十年的发展, 迄今已经积累了大量的各种地表遥感时间序列数据, 这些时间序列数据较为真实地反映了地表在一个长时间范围内的动态变化情况, 而地表变化几乎与全球变化的各个方面都密切相关, 包括全球土地利用/覆盖变化、气候变化、全球生物圈变化、环境变化等, 因此, 基于时间序列数据集(如NOAA/AVHRR、MODIS、Landsat等), 对地表趋势时空动态变化的研究对遥感学科以及与之相关各学科的发展有非常重要的意义(Boriah, 2010; Han 等, 2010; Hermosilla

等, 2015a)。

遥感时间序列对地观测技术的研究受到普遍关注, 国内外也相继发射了具备获取极高时间分辨率的遥感传感器, 包括中国的高分四号(GF-4)和“吉林一号”, 以及国外的SkySat卫星。GF-4发射于2015年12月29日, 是中国第1颗民用高轨、地球同步轨道高分辨率光学遥感卫星, 是国家高分辨率对地观测系统民用系列卫星的重要组成部分, 可与静止轨道气象卫星、高空间分辨率极轨卫星等形成有机互补, 构建全天时、全天候、高时效、宽覆盖、多尺度的综合对地观测系统。该卫星与传统的对地观测卫星相比, 其最大的特点是在具备较高空间分辨率优势的同时, 还可以对热点区

收稿日期: 2016-05-19; 修订日期: 2016-06-17; 优先数字出版日期: 2016-07-24

基金项目: 高分辨率对地观测系统重大专项(编号: 30-Y20A03-9003-15/16); 国家自然科学基金(编号: 41401474, 41301393)

第一作者简介: 赵忠明(1961—), 男, 研究员, 中国科学院遥感与数字地球研究所副所长, 研究方向为遥感影像信息提取与分析。E-mail: zhaozm@radi.ac.cn

域进行“凝视”观测,以“视频录像”的方式获得比传统卫星更多的动态信息,特别适于观测动态变化的目标,监测其瞬时特性和发生变化的过程。可以预见未来几年,静止轨道凝视卫星、低轨高分辨率视频卫星将提供丰富的高频次时间序列数据。

历史存档遥感数据促使长时间序列遥感数据的分析成为可能,研究者可以从中挖掘某种事物发展的规律或模式;而高时间分辨率传感器具备大范围、小时级甚至分钟级的快速凝视监测能力,实时性强,促使高频次时间序列遥感数据的分析成为可能,遥感科学者可以借鉴视频图像处理技术方法,实现高频次遥感时间序列快速变化检测,精确提取目标变化信息。因此,如何综合利用海量的历史数据和最新获取的高频次遥感影像提取和检测变化信息,并应用于自然物候、城市扩张、灾害和土地利用/覆盖等方面的动态监测中,已经成为遥感信息科学的研究重点(Hermosilla等,2015b;黄春波等,2015;Gómez等,2016)。

2 遥感时间序列变化检测

时间序列数据遍及现实世界的各个领域。以时间序列数据为支撑的数据挖掘技术业已在医学、信号处理、金融、机器视觉等领域得到了广泛应用。遥感时间序列影像变化检测的研究得益于其他领域时间序列分析和检测技术的发展。遥感时间序列变化检测问题类型的划分和许多遥感时间序列变化检测方法的提出也借鉴了许多传统时间序列分析和变化模式检测技术。

2.1 时间序列变化检测方法

针对时间序列变化检测在各领域的应用需求,各国学者相继提出了许多时间序列变化检测方法。

2.1.1 基于统计的变化检测方法

基于时间序列的统计特性进行变化检测起源于工业中的过程和质量控制(余柳,2010)。该方法假设在没有变化的情况下,时间序列波动将遵循一种具有特定统计参数的特定分布。变化发生后,时间序列的分布发生改变,因此导致统计参数的改变。从而可以通过检验时间序列的统计参数,来检测变化的发生及其发生的时刻。

Page(1954)提出了累积和CUSUM(CUmulative SUM)的方法,该方法用于在某个相对稳定的数据

序列中,检测出开始发生异常的数据点。所谓异常的数据点,可理解为从这点开始,整个序列的平均值或者均方差开始发生改变,进而影响到整组数据的稳定。通过检测累积时间序列均值的变化,以达到检测微小变化的目的。Inclán和Tiao(1994)提出了迭代累积平方和算法,该算法是在CUSUM算法基础上,结合时间序列方差的变化进行变化检测的。该算法假定数据序列在开始一段时间内呈现出平稳性方差,直到方差发生突变才会影响到整组数据的稳定,随后又保持一个方差直到下一个突变,反复重复上述过程,就能得到未知数目的方差突变时间。

同样考虑了基于时间序列方差的变化而进行变化检测的还有Chen和Gupta(1997),他们基于方差的变化进行了多变化点的检测,并对股价进行了变化检测。余柳(2010)则结合小波分析和CUSUM算法,检测城市快速交通事件。于明等人(2015)用非参数CUSUM算法完成异常状态的判定,完成了云环境下基于多属性信息熵的虚拟机异常检测。詹晓珊(2015)针对CUSUM算法能检测统计过程中均值的微小变化,完成了地震前后遥感数据异常分析。

2.1.2 基于分割的变化检测方法

时间序列分割的任务是将原始时间序列分割为一系列互不重叠的子序列,使得子序列内的数据元素具有某种相同的性质(李桂玲,2012)。时间序列分割也就是将数据在时间序列模式维度进行挖掘,基于时间序列分割进行变化检测,其核心思想就是由于不同子序列性质不同,认为在分割点发生了变化。

Hawkins(2001)利用动态规划的策略,采用指数模型对时间序列进行回归,基于最大似然估计进行时间序列分割,并根据模型拟合参数的变化,进行多变化点的检测。Himberg等人(2001)利用均值向量线性拟合,进行多元时间序列分割,并为其他分割模型的应用,提供了算法框架。

覃征和李爱国(2003)基于奇异值分解,自适应地选择多项式的阶数,对时间序列进行分段多项式拟合,并利用太阳黑子活动序列进行实验,验证了算法的稳健性。Sharifzadeh等人(2005)根据时间序列中变化点会导致小波迹(wavelet footprint)的不连续,检测油气生产率序列的变化。

周大燭和李敏强(2008)提出一种基于序列重要点(SIP)的时间序列分割算法:PLR_SIP,用SIP组

成的直线段近似描述时间序列。将SIP作为时间序列的分割点,反映时间序列的主要特征,最终完成基于序列重要点的时间序列分割。曹文平等(2012)先利用关键点技术,表示时间序列,再根据二次回归和离散小波变换,分割时间序列,进行汽车防盗控制系统的异常模式检测。

2.1.3 基于异常检测的变化检测方法

时间序列的一个重要特点是具有时间属性,即序列值之间具有严格的顺序,属有序数据。时间序列异常检测的关注点,与常规的变化检测有所不同,异常检测更关注于时间序列模式的临时性变化。实际上,许多变化检测算法也具备异常的检测能力,例如上述基于分割的方法。又如余宇峰等人(2014)针对水文时间序列分析与决策中存在的**数据质量问题,提出了基于滑动窗口预测的水文时间序列异常检测算法:首先基于滑动窗口对时间序列进行子序列分割,再以子序列为基础建立预测模型对未来值进行预测,并将预测值和实测值间差异范围大于预设阈值的序列点判定为异常。

对于时间序列而言,可识别的异常有2种(Cryer和Chan, 2008):加性异常AO(Additive Outlier),即只影响发生时刻的观测值的异常;新息异常IO(Innovational Outlier),即不仅作用于发生的时刻,还会对后续观测值产生影响的异常。新息异常通常表现为异常的子序列,通常采用变化检测思路进行检测。因此,本文重点关注针对加性异常的检测方法。

李权和周兴社(2011)提出一种基于KPCA的MTS异常检测方法,通过核函数隐性地**将MTS数据映射到高维特征空间中,并采用KPCA方法获取数据的主成分方向矢量作为数据的特征表达,可用于不同的数据的异常检测。

2.2 遥感时间序列变化检测

遥感时间序列具有季节性、非稳定性、区域性、多尺度性、时空自相关性、高维度和数据量巨大等特点,将前述时间序列变化检测方法直接引入遥感领域存在较多的问题。另外,由于云造成的遥感时间序列数据缺失和噪声影响等问题,也为时间序列遥感影像的变化检测带来较大的困难。

变化可以定义为表面结构的改变或者光谱/空间的运动。变化的幅度可以是非常剧烈和突发的,比如火灾;也可以是非常微妙和渐进的,比

如生物堆积(Coppin等, 2004)。针对遥感影像,尤其是时间序列遥感影像变化检测的技术,根据地表变化方式的不同,主要可分为2类(Boriah, 2010)。其一为面向突发事件引起的异常信息检测方法,其二为面向土地利用/覆盖类型的变化检测方法,前者主要针对突发事件,后者针对地表渐进的、持续的变化。

2.2.1 遥感时间序列影像异常检测

在自然状态下,地表的变化相对缓慢,呈现出显著的规律性,而一些由灾害等自然因素(例如火灾、洪灾、病虫害等)或人类活动(例如森林砍伐、城市化等)引起的事件,会扰乱这种规律性,使地表发生相对剧烈的变化(Verbesselt等, 2010c)。在自然科学领域,通常将这类事件称为扰动(disturbance)(Pickett和White, 2013)。

扰动发生后,地表发生相对剧烈的变化,在遥感影像时间序列中,反映出与正常情况下不同的模式。这种模式的变化,被称为异常(Chandola等, 2009)。通过在时间序列中检测这种异常变化,可实现对扰动的检测。借鉴时间序列分析领域的用法,本文将这类事件统称为异常事件或异常,遥感影像时间序列的异常信息检测,就是对这类异常事件的检测。

遥感时间序列异常检测主要针对突发事件(例如森林砍伐、火灾、病虫害等)引发的突变,重点关注的是时序曲线的异常表现,或者称时间序列模式的临时性变化,并通过异常检测的方式发现突变。

2.2.2 土地利用/覆盖的遥感时间序列影像变化检测

土地利用/覆盖是目前全球变化研究的核心主题之一,它不仅影响人类生存与发展的自然基础,而且影响地球生物化学圈层的结构、功能及地球系统能量与物质循环等方面。在全球、国家或区域的尺度上,土地利用的变化总在不断驱动土地覆盖的变化,这些变化信息对于全球气候变化研究、生态环境监测等领域具有重要作用。遥感影像变化检测主要利用遥感影像来检测土地覆盖转换和改变(一种覆盖类型替代了另一种覆盖类型)。一个好的变化检测方法应该回答3方面的问题:变化的区域和程度、变化类型的分布、变化的类型(From-to)。为了得到准确、全面的变化信息,近20年来研究者发明了大量的变化检测算法,很多文献对现有的变化检测算法进行分类和

综述(Radke等, 2005; 赵忠明等, 2014)。然而, 土地覆盖和土地利用在日常生活中经常被以相同或相似的定义提到, 但两者是有区别的。有可能某个土地利用类别包含多种土地覆盖种类, 致使土地利用不同导致地表覆盖类型的变化, 例如森林遭到砍伐, 变为裸地; 也有可能某个土地覆盖种类含有多个土地利用的类别。其中, 遥感时间序列土地覆盖变化检测技术是利用同一场景获取的多个时期的影像, 针对土地覆盖类型由一类转变为另一类的情况, 不仅检测变化的发生, 同时也关注变化的类型和规律(Wardlow和Egbert, 2008; Colditz等, 2011; Kleynhans等, 2011; Brown等, 2013; 钱峻屏等, 2009)。

3 遥感时间序列异常检测方法与应用

3.1 遥感时间序列异常检测方法

对于时间序列异常, 目前并没有一个统一的定义(孙梅玉, 2009)。在特定的研究和应用领域, 有特定的异常检测方法(Chandola等, 2009)。从广义上说, 异常也是一种变化, 时间序列的异常检测与变化检测, 有许多共同之处, 只是异常检测更关注于临时性的模式变化(Boriah, 2010)。因此时间序列的异常检测实际上大量借鉴了变化检测的方法(Salvador等, 2004)。

在遥感影像中进行异常事件检测, 主要采用的是变化检测的方法。与土地覆盖和土地利用的变化检测不同, 对于异常事件的检测, 通常并不关心地表变化的类型, 而重点关注异常事件引起变化的分布和变化量等信息。目前利用时间序列数据进行异常检测已应用于医学, 经济分析学等领域, 在遥感领域的异常检测研究还具有很大的发展空间(顾娟等, 2006)。目前针对遥感时间序列中异常检测的方法主要有以下几大类。

3.1.1 相似性分析方法

利用遥感影像时间序列数据进行信息提取的关键步骤是相似性分析, 即使用一定的标准定量评价目标像元实际时间序列与基于参考数据预测得到的目标像元时间序列之间的相似度, 若相似度大于一定范围, 则认为该像元在该时间点上表现正常; 反之, 则认为该像元在该时间点上发生了异常。钱峻屏等人(2007)对2005年—2006年15景Radarsat图像进行时间序列影像分割, 利用案例点的时间序列特征值对分割后的图斑进行时间序列

相似性测度, 生成时间序列案例匹配矩阵, 进一步得到了变化图斑的土地利用转化类型和变化时间; 于一凡等人(2013)分别采用马氏距离多元截尾法和马氏距离多类判别法对ETM+遥感图像进行高温目标识别, 在异常识别的基础上, 对所得的光谱特性进行深入分析, 明确出所提异常点的物理意义并提取出真正的高温目标; 贾远信等人(2015)提出了一种根据时间序列相似性度量时空淋雨的时空异常检测方法, 能有效探测到黑河流域生态水文无线传感器网络时空数据中的异常, 并能识别由于灌溉或降雨造成的伪异常。

这类方法的优势在于使用较为简单, 对于不同种类的遥感应用, 可以直接采用该方法进行判定, 直观且易于理解, 并可应用在非监督的设定下。难点在于需要使用者根据问题的特性在多种相似性测度中进行判别和选择, 且得到相似性计算结果之后需要进一步采用阈值或其它方法对于异常进行提取。

3.1.2 机器学习方法

基于数据的机器学习是现代智能技术中的重要方面, 研究从观测数据(样本)出发寻找规律, 利用这些规律对未来数据或无法观测的数据进行预测(张学工, 2000)。关于机器学习的方法主要可以划分为两大类: 一是人工神经网络, 二是支持向量机, 两类方法也是各有优缺点。

(1)人工神经网络。人工神经网络ANN(Artificial Neural Networks)是20世纪80年代迅速兴起的集计算机科学、数学、神经学等学科为一体的综合性交叉学科, 由大量称为神经处理单元的自律要素及这些自律要素相互作用形成的网络组成(蒋宗礼, 2001)。它是多年来在对神经学科研究的基础上, 经过一定的抽象、简化与模拟的人工信息处理模型, 在输出和输入之间建立一个非线性的映射关系。它力图模拟人脑的一些基本特征, 如自适应性、自组织性、容错性等, 已在模式识别、数据处理、自动控制等领域得到了广泛的应用, 也取得了相当好的成果(阴江宁等, 2010)。

Ashish Ghosh等人(2013)结合Hopfield型神经网络提出了一种基于空间上下文的非监督多时相遥感影像变化检测方法。首先利用变化向量分析得到时间序列影像的差值图像, 而后利用一种改进后的Hopfield型神经网络, 对指数型的Gibbs马尔可夫随机场最大后验概率进行估计, 对差值图中相邻像素间的空间关系进行建模, 从而进一步得到

时间序列遥感影像的变化结果。实验证明该方法可取得较好的结果。

人工神经网络在处理小规模问题上具有很好的应用效果,但是对于大规模的问题人工神经网络的构造将会非常复杂,因此不能很好地往大规模问题上扩展。

(2)支持向量机。近年来,随着非线性动力系统时间序列分析方法的发展,产生了对非平稳时间序列有效描述的新方法—支持向量机SVM(Support Vector Machine),它以Vapnik(1998)提出的统计学习理论(Statistical Learning Theory)为基础,为建立有限样本学习问题提供了一个统一的框架。SVM方法可以通过核函数实现从样本空间到高维特征空间的非线性映射,而且该方法对小样本条件下的非线性映射具有优势(毛宇清,2007;朱佳等,2010)。

Bovolo等人(2010)提出了一种将支持向量机与变化向量分析相结合的时间序列影像变化检测方法。该方法将变化检测看作是一个最小包围球问题,变化像素为其中的目标对象。首先将光谱变化向量映射到一个高维希尔伯特空间当中,计算最小体积超球面,而后再从高维空间重新恢复到原始特征空间中,即可得到一个非线性的边界,在边界之中即为目标像素也就是发生变化的像素。该方法有效利用了时间序列影像中的多维信息,更好地对变化区域进行了识别,亦可降低最终变化结果中配准残差噪声的影响。

相对于人工神经网络来看,支持向量机不仅具有相同的处理能力,而且在计算效率上也有很大的提高,但是支持向量机不仅在理论方面还有在建立模型方面都相对比较复杂,因此在实际应用中存在一定的难度(Knorr和Ng,1999;杨虎等,2004;Agrawal等,1993;向馗和蒋静坪,2007)。

(3)基于规则的方法。除了上面介绍的人工神经网络和支持向量机外还有一种机器学习方法是基于规则来实现的,该方法首先对原始数据进行聚类或分段,然后从聚类或分段的情况中得到某种规则,最后利用产生的规则构造出一个状态机,这个状态机只接受正常的模式,任何不被状态机所接受的序列都可被认为是一种异常模式,这种异常模式是偏离所产生的规则的,基于规则的方法产生的规则很容易被人读懂。

杨辰等人(2013)以江西武宁县为例,使用遥感指数时间序列轨迹分析方法,研究了适用于中国南方森林的扰动监测技术。算法首先对时间序列

轨迹做适当的分段,在最大程度保留原始时间序列扰动信号的基础上,消除由于其他原因造成的小幅波动;在完成分割算法以后,采用基于点到点的连线方法以及基于回归的连接方法进行时间序列拟合;对于得到的时间序列重构结果,将其中扰动时扰动指数大幅增加,且持续时间很短的末年作为扰动年加以提取。该方法不仅可识别森林的扰动变化,同时还可以监测植被的恢复信息,但也存在序列影像缺失导致扰动检测延后,和植被迅速恢复导致轻微扰动漏判的缺陷。

相比于其他两种机器学习方法,基于规则的方法引入了分割聚类的预处理步骤,容易对后续异常检测结果造成干扰,且需要提供较多的先验知识。但异常检测结果存在可复用、运算速度快的优点,可应用于在线异常检测问题的解决中。

3.1.3 基于模型的方法

当异常发生时,在遥感影像时间序列中,会反映出与正常情况下不同的模式,因此研究者通过建立各种时间序列模型,实现对遥感影像中异常事件的检测。目前,比较常用的模型包括基于自回归滑动平均ARMA(AutoRegressive-Moving Average)模型,基于马尔可夫模型,基于季节趋势分解模型等。ARMA模型是一种常见的平稳时间序列模型,其应用范围广泛,在遥感影像时间序列的分析中应用也相当成熟,比如Piwowar和Ledrew(2002)利用108个月的微波影像构建ARMA时间序列模型,用于北极海冰的异常检测以及未来发展趋势预测。马尔可夫模型作为一种强大的统计建模方法,在遥感领域主要用于卫星影像时间序列的分类和变化检测,Sawada和Sawada(2010)结合自组织映射(self-organizing map)方法和隐马尔可夫模型HMM(Hidden Markov Model)建立一种离散的时间序列模型,用于多时相卫星数据的异常检测。基于趋势分解模型是一种非常经典而有效的的时间序列分解模型,通过该模型能够很好地分解出季节项和趋势项。Verbesselt等人(2010a,2010b)提出了一种季节趋势的断点检测算法BFAST(Breaks For Additive Seasonal and Trend),分离出时间序列的季节项和趋势项,并分别进行变化的检测。Kong等人(2015)采用经验模态分解EMD(Empirical Mode Decomposition)方法提取NDVI时间序列的趋势项和季节项,用于森林火灾的检测,这种方法很好地解决了噪声、季节变化对真实变化信息检测的干扰,取得了较好的效果。

3.1.4 其他

针对遥感时间序列影像异常检测的研究大多借鉴于其他领域已有的积累。目前虽然取得了不错的效果,但是,不同于其他领域的时间序列,遥感时间序列影像有十分强烈的特殊性,如丰富的波谱信息,空间分布的相关性,以年为单位的自然周期性等。因此,不同于以上研究方法,一些研究学者利用遥感影像时间序列的独特性,提出了适应于遥感影像的异常检测方法。比如,Goodwin等人(2008)利用多时相的TM影像计算归一化差异湿度指数NDMI(Normalised Difference Moisture Index),根据指数序列的轨迹,对森林病虫害进行检测。Roberts和Wooster(2014)利用静止卫星影像的红外波段反演出地物亮温,并对亮温时间序列应用卡尔曼滤波方法用于火点检测。Bontemps等人(2008)利用基于对象的分析方法,考虑了时间序列间的相关性,利用SPOT影像时间序列分析了地表的年际变化。Kennedy等人(2007, 2010)利用年尺度的Landsat多时相数据,根据序列的轨迹变化,进行异常事件的识别。张连华等人(2013)基于多时相Landsat影像,计算基于缨帽变换的扰动指数,根据序列轨迹进行异常事件的检测。研究者通过充分挖掘遥感影像时间序列特有的特征,实现了对遥感时间序列影像异常更有效的检测。

3.2 基于经验模态分解的异常信息检测

利用遥感影像进行异常信息检测的过程中,往往受到噪声、季节变化等其他因素的影响;但从另一方面考虑,季节变化是遥感影像时间序列的重要特征,其中包含了丰富的信息。从时间序列中分离季节变化,是进行遥感影像时间序列异常检测必不可少的手段。经验模态分解(EMD)方法能够自适应地将非线性非平稳的数据,分解成不同频率的分量,而季节项与趋势项具有不同的频率信息(Huang等, 1998),利用这一特点,孔赞珑(2015)将EMD算法用于提取NDVI时间序列的季节项和趋势项,并在此基础上进行遥感影像时间序列异常信息的检测。该研究将基于EMD模型的遥感时间序列季节趋势分解模型成功应用于森林火灾、草原火灾等突发事件的检测中,并取得了一定的成果,以下以该研究为例详细阐述此类方法的一般流程。

3.2.1 基于趋势项异常信息检测

孔赞珑(2015)针对在趋势项中检测对异常发生时间判断不够精确的缺点,提出了一种适用于异

常检测的基于EMD的遥感影像时间序列趋势项自动提取方法,并在此基础上利用CUSUM算法进行趋势项的断点检测和精度优化,检测异常发生的地理位置和时间;最后通过森林火灾的实例,验证算法的有效性和精度。基于EMD的时间序列趋势项异常检测算法流程如图1所示。

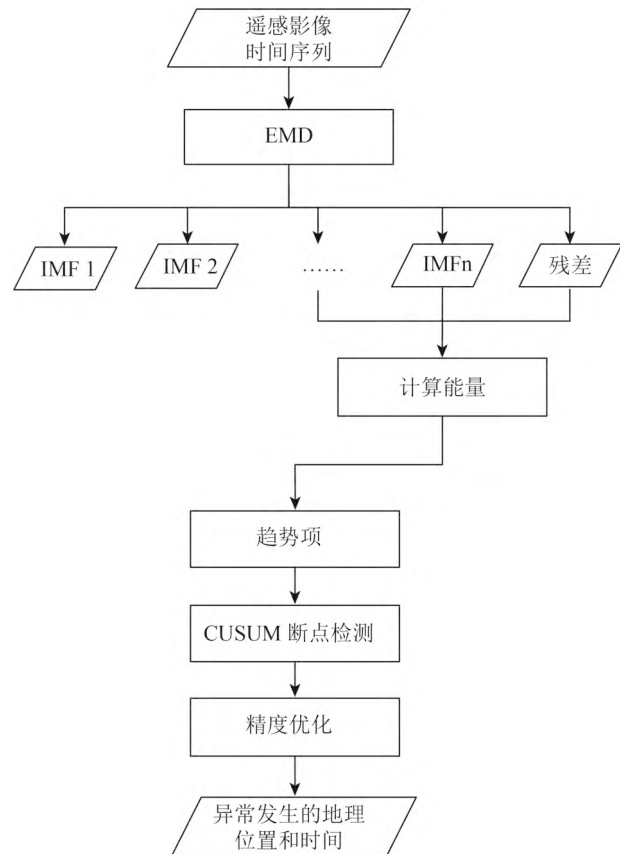


图1 基于EMD的时间序列趋势项异常检测算法流程图

Fig. 1 Workflow of anomaly detection method for trend component of satellite image time series based on EMD

选取黑龙江省伊南河林场2009年发生的特大火灾为研究实例,应用上述异常检测方法,其检测如图2所示,图2(a)是2009年5月23日的Landsat TM数据4、3、2假彩色影像,用于展示火烧迹地的范围;图2(b)是利用本文提出的算法的检测结果,检测到发生了异常的时间序列对应的像素,标记为红色,在本例中就是过火区域,绿色部分为未过火区域。检测到的过火面积一共719 km²。利用MODIS和TM半自动解译结果进行量化精度评价,分别取得91.3%和88.5%的总体检测精度,Kappa系数分别为0.76和0.63。在时间精度上,滞后了1个时间点(16 d),该算法能够满足遥感影像时间序列异常信息检测的要求。

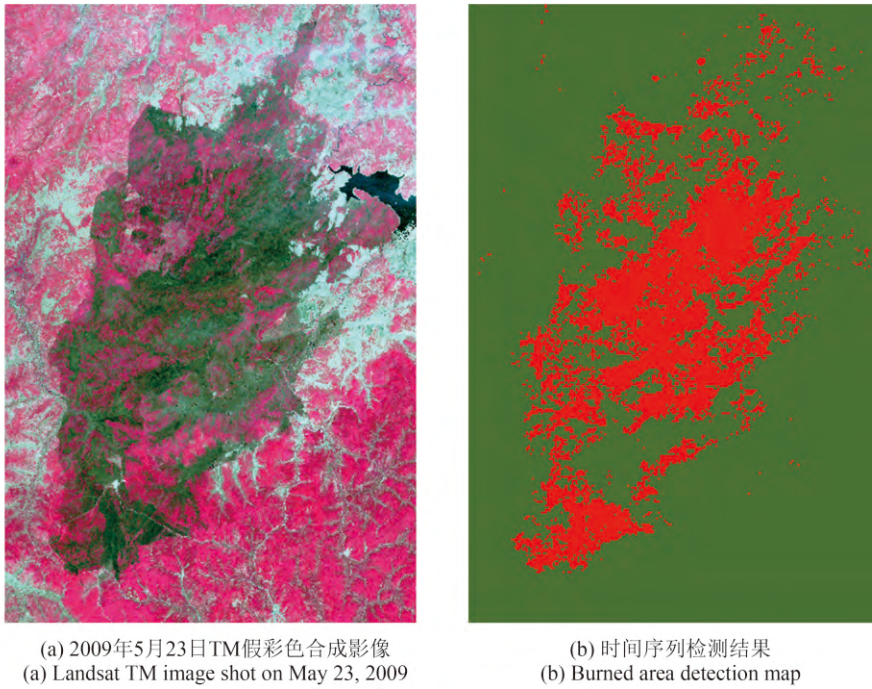


图2 森林火灾时间序列趋势项异常检测结果

Fig. 2 Forest fire detection result using trend component of time series

3.2.2 基于季节项异常信息检测

类似于上一小节所述的趋势项分解方法，孔赞珑(2015)基于EMD自动提取季节项。不同于基于趋势项的时间序列异常离线检测，本算法通过一定程度的改进，实现在季节项中进行异常的在线检测，算法的具体流程如图3所示。

选取草原火灾作为研究实例，采用上述算法，进行时间序列季节项的在线异常检测，结果如图4所示。图4为火灾发生过程中，天气状况较好的3 d的MODIS影像和检测结果。MODIS影像为7、6、5波段假彩色合成；检测结果为二值图，其中白色区域为检测到地表温度偏高的异常像素。从图4中可以看出，尽管存在较多虚警，但在线检测的方案能够较好地反映出火灾蔓延的情况，对异常进行一定程度的预警和监测，而在线检测算法也是通过牺牲精度，来提高检测的时效性。

4 遥感时间序列土地利用/覆盖变化检测方法与应用

4.1 遥感时间序列土地利用/覆盖变化检测方法

根据利用信息的不同，将现有的基于遥感时间序列数据的土地利用/覆盖变化检测方法概况为以下3类：双时相变化检测方法、基于时间序列模型的变化检测方法和基于时空数据挖掘的变化检

测方法，以下详细介绍这3类算法的区别和研究现状。

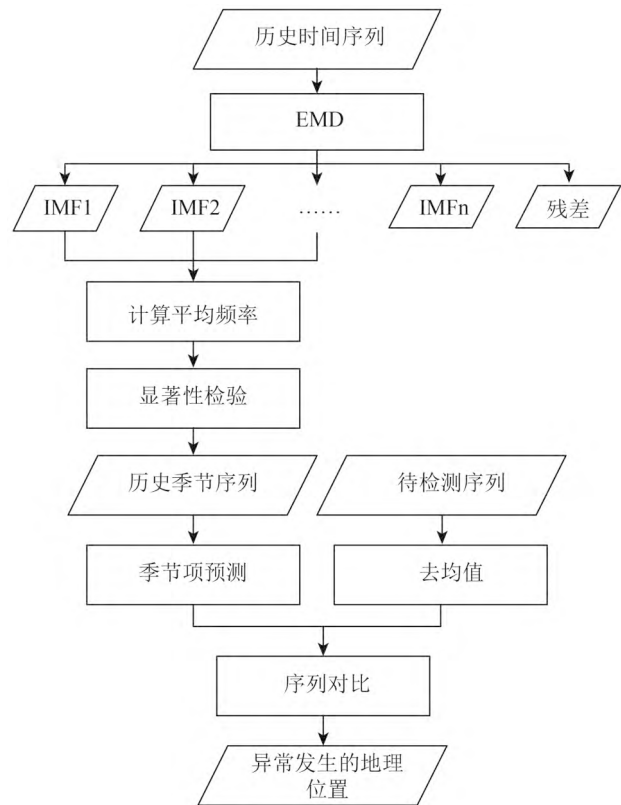


图3 基于EMD的时间序列季节项在线异常检测算法流程图
Fig. 3 Workflow of anomaly detection method for seasonal component of satellite image time series based on EMD




图 4 草原火灾时间序列季节项在线异常检测结果

Fig. 4 Grassland fire detection result using seasonal component of time series online

4.1.1 双时相变化检测方法

一些学者将基于遥感时间序列的土地覆盖变化检测问题仅作为双时相变化检测问题的扩展，

借助和改进经典的双时相变化检测方法加以解决。如Wang等人(2009)将同一年的23景MODIS植被指数影像合并为一景多波段数据，通过ISODATA

非监督聚类及决策树分类的方法生成逐年的土地覆盖分类图,以进行分类后变化检测。Bontemps等人(2012)将同一年的SPOT-VEGETATION影像合成一幅4波段影像,每个波段为一幅用3个月的日影像合成的一景无云图像,通过分割得到时空均匀的对象以提取对象特征进行分类后变化检测。Linke和McDermid(2011)利用类似的时空分割技术得到对象后,通过直接比较法提取变化对象,并对变化对象在逐个时相上分类,得到多时相的变化检测结果。Clark等人(2010)利用多年MODIS植被指数产品,通过随机选取样本并计算这些样本序列的年统计量(如均值、方差等)和物候因子(如季节长度、幅值等),训练一个随机森林分类器并进行逐年土地覆盖分类。

这一类方法的缺点在于没有利用各种土地覆盖类型在时间维上的演化信息,仅仅将序列中的一幅影像作为一个特征进行处理,且通常无法识别年内变化。

4.1.2 基于时间序列模型的变化检测方法

基于时间序列模型的土地覆盖变化检测方法以像素序列作为分析单元,首先通过拟合或平均的方法得到某种地类在指定时段内的拟合函数或参考序列,然后将新输入的时间序列与函数预测值或参考序列之间的距离作为变化检测的依据(Salmon等,2011; Kleynhans等,2012; Rodrigues等,2013)。Carrão等人(2010)利用非线性谐波模型拟合各种地类的时间序列曲线,当新输入的时间序列与模型预测值间的距离超过阈值时认为发生了变化。Mithal等人(2012)提出了一种基于子序列分割的变化检测方法,首先通过拟合一个非参数模型将时间序列分割为多个均匀的子序列,分割的时相位置就是潜在发生变化的时刻。Zhu和Woodcock(2014)提出了一种连续变化检测和分类算法CCDC(Continuous Change Detection and Classification),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,并以模型参数作为特征进行土地覆盖分类。

与双时相变化检测方法相比,此类方法能够深入挖掘遥感时间序列的时间维信息,具有较高的变化检测精度和实时性,能够检测年内变化。其缺点是以像素为分析单元,一方面,由于不考虑像素的空间和上下文特征,因而无法提取多尺度的图像空间结构,难以满足中高分辨率影像的

处理要求;另一方面,由于此类方法需要为每个像素单独训练模型,因此算法的时间复杂度较高,对存储空间和计算资源需求也较高。

4.1.3 基于时空数据挖掘的变化检测方法

为了综合利用遥感时间序列数据所能提供的丰富光谱、时间、空间信息,一些学者试图在分析影像序列的时间维变化信息的同时,兼顾影像的空间信息,提出了一系列基于时空数据挖掘的方法(Gueguen和Datcu,2007; Zurita-Milla等,2013; Zhou等,2013)。Héas和Datcu(2005)提出了一种贝叶斯分层建模的方法,利用马尔可夫随机场MRF(Markov Random Field)模型对遥感时间序列进行模拟,获取多尺度的图像光谱、空间和结构特征,并将非监督学习和人工语义标记这两步处理相结合,提取影像序列中隐含的时空演化轨迹模式,获取感兴趣的土地覆盖变化模式。Julea等人(2011)利用数据挖掘技术,结合像素的在空间分布上的一致性,引入了一种频繁子序列挖掘的方法,提取的子序列包含了图像上潜在的植物生长信息和土地覆盖变化信息。为了分析土地覆盖类型的演化规律,Vaduva等人(2013)首先用原影像序列进行两两差分,生成一组变化图序列,然后引入一种常用于文档建模的算法—隐含狄利克雷分布LDA(Latent Dirichlet Allocation)对变化图序列建模,推理潜在的土地覆盖变化模式。

这类方法的优势在于能够充分利用遥感时间序列提供的丰富时空信息,具有很强的学习能力,且适用于大数据,其问题在于通过数据挖掘得到的模式信息并不一定是土地资源管理者感兴趣的土地覆盖信息,且无法直接用于土地覆盖变化检测。

综上所述,目前利用遥感时间序列数据进行土地覆盖变化检测的研究还处于基础方法研究阶段,相关算法和模型还鲜有成功的大范围应用实例。

4.2 基于隐马尔可夫模型的遥感时间序列变化检测方法

隐马尔可夫模型HMM(Hidden Markov Model)是在马尔可夫模型基础上发展起来的一种强大的统计建模方法和时间序列分析工具。Yuan等人(2015)将该模型应用于基于遥感时间序列的土地覆盖变化检测领域,并取得了较好应用成果,以下以该研究为例详细阐述此类方法的一般流程。

由于受到植被物候的影响, 某个地区的地表一般会呈现以年为周期的季节性变化, 从而引起该地区卫星影像序列的周期性波动, 这种波动模式通常是稳定的, 它由当地的土地覆盖类型所决定。当该地区的土地覆盖类型发生变化时, 卫星影像序列的波动模式会随之发生改变, 由一种地类的波动模式转化为另一种地类的波动模式。

图5为北京首都国际机场附近2001年—2010年MODIS 4个光谱波段的时间序列示意图。从两景

Landsat TM影像上可以看出, 该地区的土地覆盖类型由耕地变成了建设用地, 引起植被水平的大幅下降。由MODIS时间序列上来看, 在2006年以前, 耕地的各个波段有显著的四季变化, 而发生变化后, 建设用地的序列没有明显的季节性变化, 且各波段的值域略有上升。通过对这两种不同的波动模式进行建模和比较, 能够达到检测变化并识别土地覆盖类型的目的。

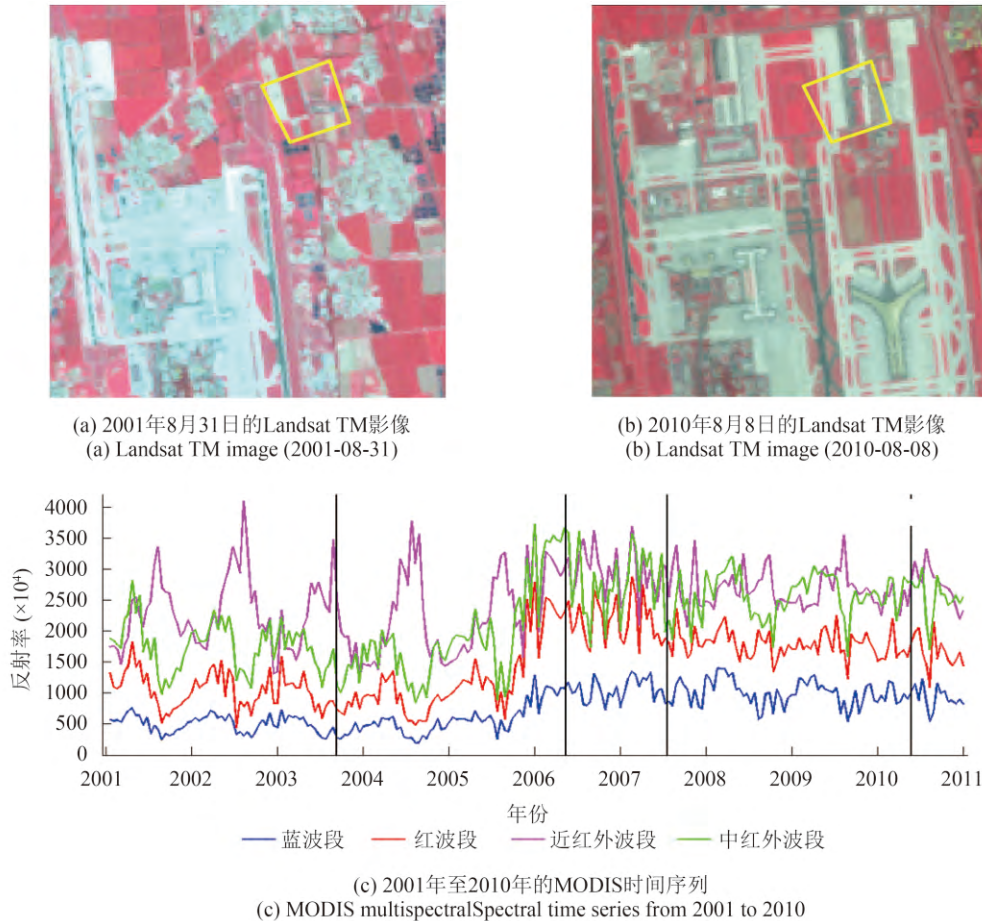


图5 2001年—2010年的MODIS多光谱时间序列及其在Landsat TM影像上的对应区域

Fig. 5 MODIS multispectral time series and the corresponding area in Landsat TM images from 2001 to 2010

为了描述不同土地覆盖类型特有的波动模式并通过波动模式的改变检测覆盖变化, 袁媛(2015)提出了一种基于HMM的连续变化检测及分类方法, 简称为HCCDC(HMM-based Continuous Change Detection and Classification)。该方法的具体实现过程是: 首先利用每种地类的年时间序列训练一个隐半马尔可夫模型HSMM(Hidden Semi-Markov Model); 其次, 通过一个时间域滑动窗口连续计算新输入影像与积累的历史影像组成的子序列与其初

始地类所属模型的相似度, 得到一条相似度序列如图6所示; 再次, 利用该相似度序列检测变化发生的时相, 模型相似度的连续、剧烈下降是检测变化的依据; 最后, 基于训练好的一组HSMM分类变化后的时间序列, 提供变化后的土地覆盖类型信息。作者采用HSMM代替了经典HMM进行遥感时间序列建模, 这是因为HSMM对状态延时进行了显式定义, 这一特性使得HSMM克服了HMM在建模时的状态延时拟合失真。




图6 基于隐马尔可夫模型的时间序列变化检测方法示意图

Fig. 6 HMM-based time series change detection method

作为一种基于时间序列模型的变化检测方法，HCCDC算法的优势主要在于建模的对象是地类而非像素，一旦训练好模型参数后，在变化检测阶段无须再次进行模型的更新与重训练，克服了此类算法变化检测及地类识别精度较低且算法费时的缺陷。因此，对于大数据量的区域级、全球级的变化检测任务，HCCDC算法具有更强的实用性。

5 结语

本文总结和评述了当前遥感时间序列影像变化检测的相关研究进展和应用情况，在此基础上，针对遥感时间序列具有季节性、非稳定性、区域性、多尺度性、时空自相关性、高维度和数据量巨大等特点，重点介绍了基于经验模态分解的遥感时间序列影像异常信息检测方法和基于隐马尔可夫模型的土地覆盖变化检测方法，并分别给出了应用案例，以期能够为相关方法研究和应用提供借鉴和参考。

综合当前相关研究的进展和状况，遥感时间序列影像变化检测主要体现出以下发展特征：

(1)大量累积的历史数据与最新发射的高时间分辨率遥感传感器为该领域研究提供了基础数据保障。特别是随着GF-4号、“吉林一号”，Skysat卫星的发射成功，高时间分辨率遥感数据的获取变得越来越容易，地面视频数据的获取也成为可

能，丰富的数据资源促使遥感时间序列影像变化检测研究进入了一个全新的发展阶段。

(2)异常信息检测和渐进、持续变化的检测是当前遥感时间序列影像变化检测的主要问题与类型。前者通常是针对突发事件进行的异常检测，后者则面向土地利用/覆盖类型相对缓慢的变化检测。

(3)借助视频分析、语音识别、金融数据分析等领域的新理论、新方法是进行遥感时间序列影像变化检测的主要研究方向。可以预料到，随着机器学习的快速发展，各种新方法必将在遥感时间序列影像变化检测中得到更加广泛的应用。

(4)减灾防灾、林业、国土、气象等是遥感时间序列影像变化检测的主要应用领域。针对不同领域的应用，如何选择合适的时间序列数据，如何紧密结合应用的目标和需求，针对性地研发适应的算法，从而以较低成本、简单的方式解决实际应用中遇到的问题，是该方法应用过程中必然遇到的挑战。

在归纳遥感时间序列影像变化检测研究中存在的问题的基础上，对今后的研究工作和未来发展方向进行展望。

(1)特定变化模式的挖掘。地表变化包括一些特定的变化模式，如土地利用/覆盖中的耕地/未利用地→建设用地、草地/林地→裸地/沙地等。利用时间序列数据，能够得到地物随时间变化的特征，从而为地表变化的信息挖掘提供了有效的数

据来源。未来可结合遥感时间序列影像的光谱和时空特征,建立特定对象变化特征库,探讨特定对象变化类型与变化特征之间的关系,研究基于特定对象变化特征库的时间序列遥感影像特定对象变化模式匹配方法,形成特定对象变化类型自动识别的模型。

(2)遥感时间序列影像亚像元变化检测。GF-4卫星的中低分辨率成像能力导致其影像易受混合像元的影响,难以保证每个像素内部具有相同的变化属性,使得小区域的微弱变化难以发现。未来可利用时间序列时间维信息,研究基于遥感时间序列影像的亚像元级变化检测方法,包括基于时间序列影像的时间域混合像元分解模型研究,以及时间数据下的亚像元定位方法研究,以提高针对不同目标地物的变化发现能力。

(3)多维EMD的多特征时间序列分解。传统的EMD分解针对单一特征,但单一特征不足以体现遥感监测目标的准确性和完整性,为更好发挥遥感数据的优势,有利于判定异常类型,可对提取到的多特征尝试多特征时间序列的EMD分解,这样不仅能够简化分析方法,还能够进行相互验证,提高异常检测的准确性。

(4)遥感时间序列影像的时空上下文模型构建。时空上下文模型作为视频处理领域较为前沿的方法,具有较好的发展前景,但是其在遥感时间序列数据处理方面的应用尚很少见。随着中高分辨率时间序列影像的积累,空间上下文信息变得越来越重要。对于高时空分辨率遥感影像来说,仅仅从时间维度进行考虑而忽略了空间维度显然不能全面发掘数据当中的有效信息。针对中高分辨率时间序列卫星影像,研究如何将时间序列中的空间、时间和光谱信息相结合,进而研究基于时空上下文模型的序列影像变化检测,将是该领域研究的一个重要方向。

(5)遥感时间序列影像变化检测标准数据集的建立。遥感高光谱数据分析研究,以及机器学习领域,通常具有标准数据集,这有利于新方法、新技术的对比验证,但目前仍缺乏遥感时间序列标准数据集,未来可针对遥感时间序列分类、变化检测等应用需求,建立标准数据集,促进领域研究进展,提升领域研究活跃度。

遥感数据的不断累积,为遥感时间序列影像变化检测研究提供了强大的数据保障,与之对应

的研究也成为遥感科学技术与应用最为热门的研究方向之一。随着未来新型高时间分辨率传感器的继续发射并投入运行,研究人员将获得更加丰富的遥感时间序列数据,因此一方面要继续引入视频处理与机器学习领域的新方法、新技术,发展更先进、更有效的遥感时间序列影像变化检测方法,另一方面要关注不同行业的应用需求,充分发挥时间序列数据的优势,为特定应用领域提供更好的数据和信息服务,从而推进遥感时间序列数据的广泛和深入应用。

参考文献(References)

- Agrawal R, Imieliński T and Swami A. 1993. Mining association rules between sets of items in large databases. *ACM SIGMOD Record*, 22(2): 207–216 [DOI: 10.1145/170036.170072]
- Bontemps S, Bogaert P, Titeux N and Defourny P. 2008. An object-based change detection method accounting for temporal dependencies in time series with medium to coarse spatial resolution. *Remote Sensing of Environment*, 112(6): 3181–3191 [DOI: 10.1016/j.rse.2008.03.013]
- Bontemps S, Langner A and Defourny P. 2012. Monitoring forest changes in Borneo on a yearly basis by an object-based change detection algorithm using SPOT-VEGETATION time series. *International Journal of Remote Sensing*, 33(15): 4673–4699 [DOI: 10.1080/01431161.2011.638336]
- Boriah S. 2010. *Time series Change Detection: Algorithms for Land Cover Change*. Minnesota: University of Minnesota
- Bovolo F, Camps-Valls G and Bruzzone L. 2009. A support vector domain method for change detection in multitemporal images. *Pattern Recognition Letters*, 31(10): 1148–1154 [DOI: 10.1016/j.patrec.2009.07.002]
- Brown J C, Kastens J H, Coutinho A C, De Castro Victoria D and Bishop C R. 2013. Classifying multiyear agricultural land use data from Mato Grosso using time-series MODIS vegetation index data. *Remote Sensing of Environment*, 130: 39–50 [DOI: 10.1016/j.rse.2012.11.009]
- Cao W P, Luo Y, Xiong Q J and Ning B. 2012. Time series segmentation algorithm based on quadratic regression. *Computer CD Software and Applications*, (18): 157, 159 (曹文平, 罗颖, 熊启军, 宁彬. 2012. 基于二次回归的时间序列分割算法. 计算机光盘软件与应用, (18): 157, 159)
- Carrão H, Gonçalves P and Caetano M. 2010. A nonlinear harmonic model for fitting satellite image time series: analysis and prediction of land cover dynamics. *IEEE Transactions on Geoscience and Remote Sensing*, 48(4): 1919–1930 [DOI: 10.1109/TGRS.2009.2035615]
- Chandola V, Banerjee A and Kumar V. 2009. Anomaly detection: a survey. *ACM Computing Surveys*, 41(3): 15 [DOI: 10.1145/

- 1541880.1541882]
- Chen J and Gupta A K. 1997. Testing and locating variance change-points with application to stock prices. *Journal of the American Statistical Association*, 92(438): 739–747 [DOI: 10.1080/01621459.1997.10474026]
- Clark M L, Aide T M, Grau H R and Riner G. 2010. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: a case study in the Dry Chaco ecoregion of South America. *Remote Sensing of Environment*, 114(11): 2816–2832 [DOI: 10.1016/j.rse.2010.07.001]
- Colditz R R, Schmidt M, Conrad C, Hansen M C and Dech S. 2011. Land cover classification with coarse spatial resolution data to derive continuous and discrete maps for complex regions. *Remote Sensing of Environment*, 115(12): 3264–3275 [DOI: 10.1016/j.rse.2011.07.010]
- Coppin P, Jonckheere I, Nackaerts K, Muys B and Lambin E. 2004. Review article digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, 25(9): 1565–1596 [DOI: 10.1080/0143116031000101675]
- Cryer J D and Chan K S. 2008. *Time Series Analysis: With Applications in R*. New York: Springer
- Ghosh A, Subudhi B N, Bruzzone L. 2013. Integration of Gibbs Markov random field and Hopfield-type neural networks for unsupervised change detection in remotely sensed multitemporal images. *IEEE Transactions on Image Processing*, 22(8): 3087–3096 [DOI: 10.1109/TIP.2013.2259833]
- Gómez C, White J C and Wulder M A. 2016. Optical remotely sensed time series data for land cover classification: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116: 55–72 [DOI: 10.1016/j.isprsjprs.2016.03.008]
- Goodwin N R, Coops N C, Wulder M A, Gillanders S, Schroeder T A and Nelson T. 2008. Estimation of insect infestation dynamics using a temporal sequence of Landsat data. *Remote Sensing of Environment*, 112(9): 3680–3689 [DOI: 10.1016/j.rse.2008.05.005]
- Gu J, Li X and Huang C L. 2006. Research on the reconstructing of time-series NDVI data. *Remote Sensing Technology and Application*, 21(4): 391–395 (顾娟, 李新, 黄春林. 2006. NDVI时间序列数据集重建方法述评. *遥感技术与应用*, 21(4): 391–395) [DOI: 10.3969/j.issn.1004-0323.2006.04.024]
- Gueguen L and Datcu M. 2007. Image time-series data mining based on the information-bottleneck principle. *IEEE Transactions on Geoscience and Remote Sensing*, 45(4): 827–838 [DOI: 10.1109/TGRS.2006.890557]
- Han P, Wang P X, Zhang S Y and Zhu D H. 2010. Drought forecasting based on the remote sensing data using ARIMA models. *Mathematical and Computer Modelling*, 51(11/12): 1398–1403 [DOI: 10.1016/j.mcm.2009.10.031]
- Hawkins D M. 2001. Fitting multiple change-point models to data. *Computational Statistics and Data Analysis*, 37(3): 323–341 [DOI: 10.1016/S0167-9473(00)00068-2]
- Héas P and Datcu M. 2005. Modeling trajectory of dynamic clusters in image time-series for spatio-temporal reasoning. *IEEE Transactions on Geoscience and Remote Sensing*, 43(7): 1635–1647 [DOI: 10.1109/TGRS.2005.847791]
- Hermosilla T, Wulder M A, White J C, Coops N C, and Hobart G W. 2015. An integrated landsat time series protocol for change detection and generation of annual gap-free surface reflectance composites. *Remote Sensing of Environment*, 158: 220–234 [DOI: 10.1016/j.rse.2014.11.005]
- Hermosilla T, Wulder M A, White J C, Coops N C and Hobart G W. 2015. Regional detection, characterization, and attribution of annual forest change from 1984 to 2012 using Landsat-derived time-series metrics. *Remote Sensing of Environment*, 170: 121–132 [DOI: 10.1016/j.rse.2015.09.004]
- Himberg J, Korpioja K, Mannila H, Tikanmaki J and Toivonen H T T. 2001. Time series segmentation for context recognition in mobile devices//*Proceedings IEEE International Conference on Data Mining*. San Jose, CA: IEEE: 203–210 [DOI: 10.1109/ICDM.2001.989520]
- Huang C B, Dian Y Y, Zhou Z X, Wang D and Chen R D. 2015. Forest change detection based on time series images with statistical properties. *Journal of Remote Sensing*, 19(4): 657–668 (黄春波, 佘袁勇, 周志翔, 王娣, 陈瑞冬. 2015. 基于时间序列统计特性的森林变化监测. *遥感学报*, 19(4): 657–668) [DOI: 10.11834/jrs.20154104]
- Huang N E, Shen Z, Long S R, Wu M C, Shih H H, Zheng Q A, Yen N C, Tung C C and Liu H H. 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings: Mathematical, Physical and Engineering Sciences*, 454(1971): 903–995 [DOI: 10.1098/rspa.1998.0193]
- Inclán C and Tiao G C. 1994. Use of cumulative sums of squares for retrospective detection of changes of variance. *Journal of the American Statistical Association*, 89(427): 913–923 [DOI: 10.1080/01621459.1994.10476824]
- Jia Y X, Guo J W, Liu F. 2015. A Study of Spatiotemporal Outlier Detection of Automatic Observing Data based on Time Series Similarity. *Remote Sensing Technology and Application*. 30(4): 700–705 (贾远信, 郭建文, 刘丰. 2015. 基于时间序列相似性的自动观测数据时空异常探测方法研究. *遥感技术与应用*, 30(4): 700–705)
- Jiang Z L. 2001. *Introduction to Artificial Neural Networks*. Beijing: Higher Education Press (蒋宗礼. 2001. *人工神经网络导论*. 北京: 高等教育出版社)
- Julea A, Méger N, Bolon P, Rigotti C, Doin M P, Lasserre C, Trouvé E and Lazarescu V N. 2011. Unsupervised spatiotemporal mining of satellite image time series using grouped frequent sequential patterns. *IEEE Transactions on Geoscience and Remote Sensing*, 49(4): 1417–1430 [DOI: 10.1109/TGRS.2010.2081372]
- Kennedy R E, Yang Z Q and Cohen W B. 2010. Detecting trends in

- forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr—Temporal segmentation algorithms. *Remote Sensing of Environment*, 114(12): 2897–2910 [DOI: 10.1016/j.rse.2010.07.008]
- Kleynhans W, Olivier J C, Wessels K J, Salmon B P, Van Den Bergh F and Steenkamp K. 2011. Detecting land cover change using an extended Kalman filter on MODIS NDVI time-series data. *IEEE Geoscience and Remote Sensing Letters*, 8(3): 507–511 [DOI: 10.1109/LGRS.2010.2089495]
- Kleynhans W, Salmon B P, Olivier J C, Van Den Bergh F, Wessels K J, Grobler T L and Steenkamp K C. 2012. Land cover change detection using autocorrelation analysis on MODIS time-series data: detection of new human settlements in the Gauteng province of South Africa. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(3): 777–783 [DOI: 10.1109/JSTARS.2012.2187177]
- Knorr E M and Ng R T. 1999. Finding intensional knowledge of distance-based outliers//*Proceedings of the 25th International Conference on Very Large Data Bases*. San Francisco, CA: Morgan Kaufmann Publishers Inc.: 211–222
- Kong Y L. 2015. Anomaly Detection in Remote Sensed Imagery Time Series Based on EMD. Beijing: Institute of Remote Sensing and Digital Earth Chinese Academy of Sciences (孔赞珑. 2015. 基于经验模态分解的遥感影像时间序列异常信息检测算法研究. 北京: 中国科学院遥感与数字地球研究所)
- Kong Y L, Meng Y, Li W, Yue A Z and Yuan Y. 2015. Satellite image time series decomposition based on EEMD. *Remote Sensing*, 7(11): 15583–15604 [DOI: 10.3390/rs71115583]
- Li G L. 2012. Research on Time Series Segmentation and Discord Discovery. Wuhan: Huazhong University of Science and Technology (李桂玲. 2012. 时间序列的分割及不一致发现研究. 武汉: 华中科技大学)
- Li Q and Zhou X S. 2011. Multivariate time series anomaly detection method based on KPCA. *Computer Measurement and Control*, 19(4): 822–825 (李权, 周兴社. 2011. 基于KPCA的多变量时间序列数据异常检测方法研究. 计算机测量与控制, 19(4): 822–825)
- Linke, J. and Mcdermid, G. J. 2011. A conceptual model for multi-temporal landscape monitoring in an object-based environment. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 4(2), 265–271 [DOI: 10.1109/JSTARS.2010.2045881]
- Mao Y Q. 2007. Application Study on Prediction and Analysis for Nonstationary Time Series Based on the SVM Method. Nanjing: Nanjing University of Information Science and Technology (毛宇清. 2007. 基于支持向量机方法的非平稳时间序列预测研究. 南京: 南京信息工程大学 [DOI: 10.7666/d.y1079977])
- Mithal V, O'Connor Z, Steinhäuser K, Boriah S, Kumar V, Potter C S and Klooster S A. 2012. Time series change detection using segmentation: a case study for land cover monitoring//*Proceedings of the 2012 Conference on Intelligent Data Understanding*. Boulder, CO: IEEE: 63–70 [DOI: 10.1109/CIDU.2012.6382202]
- Mithal V, Khandelwal A, Boriah S, Steinhäuser K and Kumar V. 2013. Change Detection from Temporal Sequences of Class Labels: Application to Land Cover Change Mapping. In *SIAM International Conference on Data Mining, SDM*. SIAM.
- Page E S. 1954. Continuous inspection schemes. *Biometrika*, 41: 100–115
- Pickett S T A and White P S. 1985. *The Ecology of Natural Disturbance and Patch Dynamics*. Orlando, Florida: Academic Press
- Piwowar J M and Ledrew E F. 2002. ARMA time series modelling of remote sensing imagery: a new approach for climate change studies. *International Journal of Remote Sensing*, 23(24): 5225–5248 [DOI: 10.1080/01431160110109552]
- Qian J P, Li X, Ye J A, Ai B, Chen X Y and Wang F. 2009. Density-based anomaly detection for short-term land use-land cover change detection using repeat-pass Radarsat images. *Journal of Remote Sensing*, 13(3): 491–507 (钱峻屏, 黎夏, 叶嘉安, 艾彬, 陈晓越, 王芳. 2009. 基于时空域密度异常的土地利用/土地覆盖短期变化检测. 遥感学报, 13(3): 491–507) [DOI: 10.11834/jrs.20090312]
- Qin Z and Li A G. 2003. Robust optimization segment for time series data. *Journal of Xi'an Jiaotong University*, 37(4): 338–342 (覃征, 李爱国. 2003. 时间序列数据的稳健最优分割方法. 西安交通大学学报, 37(4): 338–342)
- Radke R J, Andra S, Al-Kofahi O and Roysam B. 2005. Image change detection algorithms: a systematic survey. *IEEE Transactions on Image Processing*, 14(3): 294–307 [DOI: 10.1109/TIP.2004.838698]
- Roberts G and Wooster M J. 2014. Development of a multi-temporal Kalman filter approach to geostationary active fire detection and fire radiative power (FRP) estimation. *Remote Sensing of Environment*, 152: 392–412 [DOI: 10.1016/j.rse.2014.06.020]
- Rodrigues A, Marçal A R S and Cunha M. 2013. Identification of potential land cover changes on a continental scale using NDVI time-series from SPOT VEGETATION. *International Journal of Remote Sensing*, 34(22): 8028–8050 [DOI: 10.1080/01431161.2013.828184]
- Salmon B P, Olivier J C, Wessels K J, Kleynhans W, Van Den Bergh F and Steenkamp K C. 2011. Unsupervised land cover change detection: meaningful sequential time series analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(2): 327–335 [DOI: 10.1109/JSTARS.2010.2053918]
- Salvador S, Chan P and Brodie J. 2004. Learning states and rules for time series anomaly detection//*Proceedings of the 17th International Florida Artificial Intelligence Research Society Conference*. Miami Beach, Florida, USA: FLAIRS: 306–311
- Sawada Y and Sawada H. 2010. Development of a discrete time-series model for vegetation monitoring//*Proceedings of International Archives of the Photogrammetry, Remote Sensing and Spatial In-*

- formation Science, Volume XXXV III, Part 8. Kyoto Japan: [s.n.]
- Sharifzadeh M, Azmoodeh F and Shahabi C. 2005. Change detection in time series data using wavelet footprints//Medeiros C B, Egenhofer M J and Bertino E. *Advances in Spatial and Temporal Databases*. Berlin Heidelberg: Springer: 127–144 [DOI: 10.1007/11535331_8]
- Sun M Y. 2009. *Research on Key Issues of Stochastic Non-stationary Time Series Data Mining Based on Fractal Theory*. Shanghai: Donghua University (孙梅玉. 2009. 基于分形的非平稳时间序列挖掘关键技术研究. 上海: 东华大学 [DOI: 10.7666/d.y1864904])
- Vaduva, C., Gavati, I., and Dăcu, M. 2013. Latent dirichlet allocation for spatial analysis of satellite images. *IEEE Transactions on Geoscience & Remote Sensing*, 51(05): 2770–2786 [DOI: 10.1109/TGRS.2012.2219314]
- Verbesselt J, Hyndman R, Newnham G and Culvenor D. 2010a. Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment*, 114(1): 106–115 [DOI: 10.1016/j.rse.2009.08.014]
- Verbesselt J, Hyndman R, Zeileis A and Culvenor D. 2010b. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. *Remote Sensing of Environment*, 114(12): 2970–2980 [DOI: 10.1016/j.rse.2010.08.003]
- Verbesselt J, Hyndman R, Newnham G and Culvenor D. 2010c. Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment*, 114(1): 106–115 [DOI: 10.1016/j.rse.2009.08.014]
- Vapnik V N, Vapnik V. 1998. *Statistical learning theory*. New York: Wiley
- Wang W, Hu H X and Hu J. 2009. Land cover change detection based on MODIS 250m vegetation index time series data//Proceedings of the 17th IEEE International Conference on Geoinformatics. Fairfax, VA: IEEE: 1–6 [DOI: 10.1109/GEOINFORMATICS.2009.5293409]
- Wardlow B D and Egbert S L. 2008. Large-area crop mapping using time-series MODIS 250m NDVI data: an assessment for the U. S. Central Great Plains. *Remote Sensing of Environment*, 112(3): 1096–1116 [DOI: 10.1016/j.rse.2007.07.019]
- Xia L S. 2014. *Research on Fault Diagnosis and Related Algorithm Based on Hidden Markov Model*. Wuhan: Huazhong University of Science and Technology (夏丽莎. 2014. 基于隐马尔可夫模型的故障诊断及算法研究. 武汉: 华中科技大学)
- Xiang K and Jiang J P. 2007. Study on symbolization analysis of time series. *Pattern Recognition and Artificial Intelligence*, 20(2): 154–161 (向旭, 蒋静坪. 2007. 时间序列的符号化方法研究. 模式识别与人工智能, 20(2): 154–161) [DOI: 10.3969/j.issn.1003-6059.2007.02.003]
- Yang C, Shen R P, Yu D W, Liu R G and Chen J M. 2013. Forest disturbance monitoring based on the time-series trajectory of remote sensing index. *Journal of Remote Sensing*, 17(5): 1246–1263 (杨辰, 沈润平, 郁达威, 刘荣高, 陈镜明. 2013. 利用遥感指数时间序列轨迹监测森林扰动. 遥感学报, 17(5): 1246–1263) [DOI: 10.11834/jrs.20132308]
- Yang H, Wang H Q and Cheng D J. 2004. Series outlier data mining based on Forecastment. *Computer Science*, 31(4): 117–119, 146 (杨虎, 王会琦, 程代杰. 2004. 基于预测的序列异常数据挖掘. 计算机科学, 31(4): 117–119, 146) [DOI: 10.3969/j.issn.1002-137X.2004.04.031]
- Yin J N, Xiao K Y, Li N and Zou W. 2010. Application of BP neural network in the classification of geo-chemical survey data. *Geological Bulletin of China*, 29(10): 1564–1571 (阴江宁, 肖克炎, 李楠, 邹伟. 2010. BP神经网络在化探数据分类中的应用. 地质通报, 29(10): 1564–1571) [DOI: 10.3969/j.issn.1671-2552.2010.10.022]
- Yuan Y, Meng Y, Lin L, et al. 2015. Continuous Change Detection and Classification Using Hidden Markov Model: A Case Study for Monitoring Urban Encroachment onto Farmland in Beijing[J]. *Remote Sensing*, 7: 15318–15339
- Yu L. 2010. *Development and Evaluation of W-CUSUM Incident Detection Algorithm Based on Mobile Source Data for Urban Expressways*. Beijing: Beijing Jiaotong University (余柳. 2010. 基于移动源数据的城市快速交通事件检测W-CUSUM算法与评价. 北京: 北京交通大学)
- Yu Y F, Pan J, Xing L X. 2013. Identification of High Temperature Targets in Remote Sensing Imagery Based on Mahalanobis Distance. *Remote Sensing Information*, 28(5) (于一凡, 潘军, 邢立新, 等. 2013. 基于马氏距离的遥感图像高温目标识别方法研究. 遥感信息, 28(5))
- Yu M, Zhang Y, Liu C and Zhang D D. 2015. Anomaly detection of virtual machines based on multi-attribute entropy in cloud computing environments. *Journal of Huazhong University of Science and Technology (Nature Science Edition)*, 43(5): 63–67 (于明, 张雨, 刘畅, 张丹丹. 2015. 云环境下基于多属性信息熵的虚拟机异常检测. 华中科技大学学报(自然科学版), 43(5): 63–67) [DOI: 10.13245/j.hust.150512]
- Yu Y F, Zhu Y L, Wan D S and Guan X Z. 2014. Time series outlier detection based on sliding window prediction. *Journal of Computer Applications*, 34(8): 2217–2220 (余宇峰, 朱跃龙, 万定生, 关兴中. 2014. 基于滑动窗口预测的水文时间序列异常检测. 计算机应用, 34(8): 2217–2220) [DOI: 10.11772/j.issn.1001-9081.2014.08.2217]
- Yuan Y. 2015. *Change Detection in Remote Sensing Time Series-Based on Hidden Markov Model*. Beijing: Institute of Remote Sensing and Digital Earth Chinese Academy of Sciences (袁媛. 2015. 基于隐马尔可夫模型的遥感时间序列变化检测方法研究. 北京: 中国科学院遥感与数字地球研究所)
- Yuan Y, Meng Y, Lin L, Sahli H, Yue A Z, Chen J B, Zhao Z M, Kong Y L and He D X. 2015. Continuous change detection and classification using hidden Markov model: a case study for monitoring urban encroachment onto farmland in Beijing. *Remote Sensing*,

- 7(11): 15318–15339 [DOI: 10.3390/rs71115318]
- Zhan X S. 2015. Anomaly Analysis of the Sensing Data before and after the Earthquakes. Fuzhou: Fujian Normal University (詹晓珊. 2015. 地震前后遥感数据异常分析. 福州: 福建师范大学)
- Zhang L H, Pang Y, Yue C R and Li Z Y. 2013. Forest disturbance automatic identification method based on time series Landsat image of tasseled cap transformation. *Forest Inventory and Planning*, 38(2): 6–12, 19. (张连华, 庞勇, 岳彩荣, 李增元. 2013. 基于缨帽变换的景洪市时间序列Landsat影像森林扰动自动识别方法研究. *林业调查规划*, 38(2): 6–12, 19) [DOI: 10.3969/j.issn.1671-3168.2013.02.002]
- Zhang X G. 2000. Introduction to statistical learning theory and support vector machines. *Acta Automatica Sinica*, 26(1): 32–42 (张学工. 2000. 关于统计学习理论与支持向量机. *自动化学报*, 26(1): 32–42)
- Zhao Z M, Meng Y and Wang C Y. 2014. *Remote Sensing Image Processing*. Beijing: Science Press (赵忠明, 孟瑜, 汪承义. 2014. 遥感图像处理. 北京: 科学出版社)
- Zhou D Z and Li M Q. 2008. Time series segmentation based on series importance point. *Computer Engineering*, 34(23): 14–16 (周大镛, 李敏强. 2008. 基于序列重要点的时间序列分割. *计算机工程*, 34(23): 14–16) [DOI: 10.3969/j.issn.1000-3428.2008.23.006]
- Zhou F Q, Zhang A N and Townley-Smith L. 2013. A data mining approach for evaluation of optimal time-series of MODIS data for land cover mapping at a regional level. *ISPRS Journal of Photogrammetry and Remote Sensing*, 84: 114–129 [DOI: 10.1016/j.isprsjprs.2013.07.008]
- Zhu J, Wang Z H, Jin T L and Hao X J. 2010. Combination of wavelet decomposition and least square support vector machine to Forecast atmospheric ozone content time series. *Climatic and Environmental Research*, 2010, 15(3): 295–302 (朱佳, 王振会, 金天力, 郝晓静. 2010. 基于小波分解和最小二乘支持向量机的大气臭氧含量时间序列预测. *气候与环境研究*, 2010, 15(3): 295–302) [DOI: 10.3878/j.issn.1006-9585.2010.03.09]
- Zhu Z and Woodcock C E. 2014. Continuous change detection and classification of land cover using all available Landsat data. *Remote Sensing of Environment*, 144: 152–171 [DOI: 10.1016/j.rse.2014.01.011]
- Zurita-Milla R, Van Gijsel J A E, Hamm N A S, Augustijn P W M and Vrieling A. 2013. Exploring spatiotemporal phenological patterns and trajectories using self-organizing maps. *IEEE Transactions on Geoscience and Remote Sensing*, 51(4): 1914–1921 [DOI: 10.1109/TGRS.2012.2223218]

Review of remotely sensed time series data for change detection

ZHAO Zhongming¹, MENG Yu¹, YUE Anzhi¹, HUANG Qinqing¹, KONG Yunlong^{1,2}, YUAN Yuan^{1,2},
LIU Xiaoyi^{1,2}, LIN Lei^{1,2}, ZHANG Mengmeng³

1. Institute of Remote Sensing and Digital Earth, Chinese Academy of Science, Beijing 100101, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China;

3. College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China

Abstract: As a result of the increasingly convenient access to high temporal resolution data, and even video remote sensing data, a large amount of historical data have accumulated in recent years. Accordingly, change detection technology using remote sensing time series data has achieved rapid development and has become a hot research field in remote sensing, especially after the successful launch of “GF-4”, “Jilin No.1”, and Skysat satellites. Thus, change detection research with time series remote sensing data has entered a brand new stage.

This review systematically summarizes the research progress and application of Remote Sensing Series Data Change Detection (RSSD-CD). Considering the significance and advantage of applying time series analysis in change detection, we start this work by identifying the time series change detection methods in other fields. Then, according to the requirements of RSSDCD, we divide the methods into two categories: methods for anomaly detection for emergencies and methods for the detection of gradual and constant changes in land use/cover types. This review presents the latest progress and methods for these two types of purposes and presents discussions about their advantages and disadvantages. The remote sensing time series data exhibit the following characteristics: seasonality, instability, locality, multi-scale, time-space autocorrelation, multi-dimension, and huge quantity. This review introduces an anomaly detection method based on empirical mode decomposition and a land use/cover gradual change detection method based on hidden a Markov model. Instances for both approaches are offered as references for related research and application. A conclusion about the latest trends and existing issues in this field is drawn after tracking recent research on RSSDCD. Future works are also discussed.

Key words: time series, change detection, anomaly detection, land use/cover, empirical mode decomposition, hidden Markov model

Supported by National Natural Science Foundation of China (No. 41401474, 41301393)