

# 基于集成学习的海岸带变化检测方法研究

王娟<sup>1</sup>, 赵吉祥<sup>2</sup>, 单春芝<sup>1</sup>, 高晓慧<sup>1</sup>

(1. 国家海洋局北海环境监测中心 青岛 266000; 2. 中国石油大学(华东)海洋与空间信息学院 青岛 266000)

**摘要:**随着我国自主研发卫星组网的不断完善,利用遥感变化检测技术进行海岸带变化检测成为海岸带监测的重要手段。针对沿海地区的变化信息提取,文章首先利用多特征构建差异影像,在此基础上采用两种集成学习方式:随机森林(Random Forest)和极端梯度提升(XGBoost),进行试验区的变化检测,并与传统的机器学习SVM、经典的变化检测方法CVA和IR-MAD进行对比,结果表明集成学习进行变化信息提取效率远超其余方式,且XGBoost在变化信息提取精度方面具有一定优势。研究成果对海岸带及海域使用开展自动化变化监测和海岸带监督管理具有重要意义。

**关键词:**海岸带;变化检测;集成学习;随机森林;极端梯度提升

中图分类号:P74;TP751

文献标志码:A

文章编号:1005-9857(2021)07-0048-07

## Research on Coastal Zone Change Detection Method Based on Ensemble Learning

WANG Juan<sup>1</sup>, ZHAO Jixiang<sup>2</sup>, SHAN Chunzhi<sup>1</sup>, GAO Xiaohui<sup>1</sup>

(1. North China Sea Environmental Monitoring Center, SOA, Qingdao 266000, China; 2. China University of Petroleum(East China), College of Oceanography and Space Informatics, Qingdao 266000, China)

**Abstract:** It is of great significance to carry out automatic monitoring of coastal zone and sea area use for Coastal Zone Supervision and Management. With the continuous improvement of independent research and development of satellite network in China, remote sensing change detection technology has become an important means of coastal zone monitoring. According to the change information extraction of coastal areas, this paper first used multi features to construct different images, and then used two integrated learning methods: Random Forest and eXtreme Gradient Boosting (XGBoost) were used to detect changes in the experimental area, and compared with traditional machine learning SVM, CVA and IR-MAD. The results showed that the efficiency of change information extraction by integrated learning was far higher than that of other methods, and XGBoost had some advantages in the accuracy of change information extraction.

**Keywords:** Coastal zone, Change detection, Ensemble learning, Random forest, XGBoosting

收稿日期:2020-08-10;修订日期:2021-06-21

基金项目:国家重点研发计划(2018YFC1407605).

作者简介:王娟,高级工程师,硕士,研究方向为海洋遥感监测技术

通信作者:赵吉祥,硕士研究生,研究方向为遥感变化检测

## 0 引言

海岸带地区资源丰富,区位优势明显,人类生产生活和经济活动相对密集,但该地域海陆相互作用复杂,生态环境脆弱。随着经济的快速发展,海岸带地区的各类生产建设活动日益频繁,对资源环境造成了巨大压力<sup>[1]</sup>。随着全国海岸带监督管理的不断加强,各省市分别出台相应的海岸带开发利用及保护等条例,海岸带及海域使用监管空前严格。在我国自主研发的卫星组网不断完善的背景下,高时空分辨率的海岸带及海域使用动态变化监测已成为高效的监管手段<sup>[2]</sup>。现有的业务体系大多采用目视解译方法,亟须开展相关的自动化变化监测来提高工作效率和准确度。

变化检测能够从不同时期的遥感影像中确定地表的变化,自遥感技术诞生以来一直是众多学者研究的焦点问题之一。李德仁<sup>[3]</sup>对比分析了7种变化检测常用的手段,指出自动变化检测是未来发展的方向。国内外学者提出了大量的算法模型,从变化信息提取的角度主要分为阈值法、机器学习和深度学习3种方式。阈值法是指直接利用阈值分割差异影像从而提取变化信息,如魏立飞等<sup>[4]</sup>基于融合后的影像进行自适应阈值确定,提取变化信息。Chehata N等<sup>[5]</sup>利用均值漂移分割算法提取风暴后的受灾信息。阈值法简单易行,但是在复杂情况下难以用一个单一的阈值提取变化信息,精度受限。深度学习近年来迅速发展,从最初的图像识别、文本分析扩展至各个领域,部分学者利用深度学习方式提取变化信息,如张鑫龙等<sup>[6]</sup>构建并训练了高斯-伯努利深度限制玻尔兹曼机模型,以提取变化和未变化区域深层特征,进而完成变化检测。杜博等<sup>[7]</sup>提出深度慢特征分析用于遥感图像的变化检测,在测试数据集上取得了较好的效果。深度学习需要大量的训练样本,同时一个模型的训练需要大量的参数调节,在实际应用中较难实现。

综合来看,以机器学习为代表的算法模型构建简单,在小样本状态下能够实现变化信息的自动提取,相对于传统算法和深度学习方法仍有优势。机器学习算法如支持向量机(Support Vector Machine, SVM)等将变化检测问题转变成分类问题,通过样

本训练模型识别提取变化信息,如李亮等<sup>[8]</sup>采用贝叶斯最小错误理论提取变化;王志盼等<sup>[9]</sup>利用SVM进行高分辨率遥感影像的建筑物变化检测。集成学习是机器学习的一种,通过构造多个学习器完成学习任务,能够获得比单一分类器更加优秀的性能,是机器学习近年来发展的热点。本研究针对沿海试验区,利用两种集成学习方式:随机森林(Random Forest)和极端梯度提升(XGBoost),进行变化检测试验,并与经典的变化检测方法和传统机器学习方式进行对比,验证集成学习算法开展海岸带地区变化检测的优势。

## 1 研究方法

### 1.1 数据及预处理

获取2018年10月和12月的两景GF-1卫星影像,覆盖范围为山东省蓬莱市某处在建港口,该处位于渤海黄海交界海域,临近蓬莱阁风景区,与长岛县隔海相望。获取的GF-1卫星影像相隔两月,为融合后三波段(红、绿、蓝)真彩色影像,分辨率2 m,像元数量1 550×2 156,经过了初步大气校正、地形校正和严格的图像配准。

图像在不同季节成像,由于外部原因造成的图像间辐射差异和植被等地物自然变化带来的季相差异将会给变化检测造成严重干扰<sup>[10]</sup>,本研究采用文献<sup>[11]</sup>中的方法<sup>[11]</sup>,选择18个伪不变特征点(PIF)建立回归模型对两景影像进行相对辐射校正。经过检验,两幅影像在3个波段上的相关性指数均大于90%,说明回归模型拟合效果较好,校正后影像如图1所示。

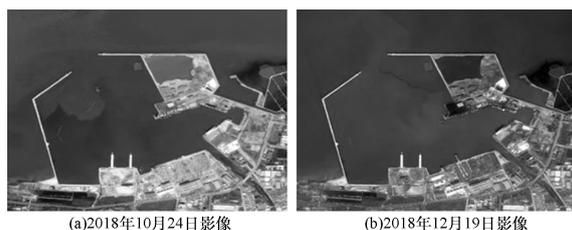


图1 相对辐射校正后影像

### 1.2 特征提取

#### 1.2.1 纹理特征

高分辨率遥感影像光谱数量较少,空间纹理信息丰富,根据相关学者研究,在变化检测中加入纹

理特征能够提高变化检测的精度<sup>[12]</sup>。灰度共生矩阵(GLCM)是一种基于统计的纹理特征描述方式,由 Haralick 等<sup>[13]</sup>在 1973 年提出。在灰度共生矩阵的基础上,Haralick 等人定义了 14 个纹理特征,根据 Ulaby 等<sup>[14]</sup>的研究,14 个特征中只有 4 个不相关的特征:二阶矩(Second Moment)、对比度(Contrast)、相关性(Correlation)和熵(Entropy)。

为进一步突出图像纹理特征,除 GLCM 外,选用局部二值模型(LBP)进行进一步提取。LBP 特征具有灰度不变性和旋转不变性,可以作为灰度共生矩阵纹理特征的补充<sup>[15]</sup>。

本研究在 0°、45°、90°和 135°的方向上进行提取灰度共生矩阵的 4 个特征值:二阶矩(Second Moment)、对比度(Contrast)、相关性(Correlation)和熵(Entropy),最后各自取 4 个方向上的平均值作为最终特征。由于图像中部分地物尺度较小,选择 3×3 窗口提取两景影像的 LBP 纹理特征。

### 1.2.2 可见光波段差异植被指数(VDVI)

影像分别于 10 月和 12 月采集,植被覆盖有明显变化,因此选择能够突出绿色植被信息的特征进行提取。健康绿色植被在绿光和近红外波段有较强反射作用,而在蓝光和红光波段有吸收作用,根据这一原理对植被识别主要依赖可见光—近红外波段的组合变化,增强植被信息的同时使非植被信息最小化,如常见的归一化植被指数 NDVI、增强型植被指数 EVI 等<sup>[16]</sup>。

本实验数据为融合完成的三波段真彩色影像,缺失红外波段信息。因此选择可见光波段差异植被指数 VDVI 进行提取,该指数利用绿色植被在不同波段的反射吸收特性,通过对波段的组合能够增强植被信息,相关实验证明 VDVI 指数对于绿色植被具有较好的提取效果<sup>[17]</sup>。计算如公式(1)所示。

$$VDVI = \frac{2\rho_{green} - (\rho_{red} + \rho_{blue})}{2\rho_{green} + \rho_{red} + \rho_{blue}} \quad (1)$$

式中: $\rho_{green}$ 代表绿色波段反射率; $\rho_{red}$ 代表红色波段反射率; $\rho_{blue}$ 代表蓝色波段反射率。

### 1.2.3 形态学建筑物指数(MBI)

该地区正在建设中,建筑物发生变化可能性较大,因此选择相关特征突出建筑物信息。形态学建筑物指数(MBI)由黄昕等<sup>[18]</sup>提出,通过基本的形态

学重建,对影像进行粒度分析和不同方向上的特征计算,能够有效描述建筑物的特征(如亮度、大小、对比度和方向性等)。

首先提取影像各个波段中灰度值最大的像元组成亮度图像,有研究表明建筑物的反射能够产生较大的灰度值,如式(2)所示。

$$b(x) = \max_{1 \leq k \leq K} (M_k(x)) \quad (2)$$

式中: $M_k(x)$ 为像素点  $x$  在波段  $k$  上的灰度值; $b(x)$ 为该像素点亮度。

在亮度图像的基础上利用形态学基本运算执行形态学重建,如式(3)所示。

$$THR^s(b) = b - \gamma_{RE}^s(b) \quad (3)$$

式中: $S$ 为结构元素的大小; $\gamma_{RE}^s$ 为重建的开运算; $THR^s$ 为重建的顶帽运算。

在不同方向求取运算结果后求平均,如式(4)所示。

$$\overline{THR^s}(b) = \overline{mean}_{dir}(THR^{s,dir}(b)) \quad (4)$$

式中: $dir$ 为结构元素  $S$  不同的方向; $\overline{THR^s}$ 为重建顶帽运算在不同方向上的平均值。

由于高分辨率图像中的建筑物显示出不同大小、形状、高度和面积的复杂空间模式,因此将多尺度  $THR$  建立在不同形态剖面上,能够描述建筑的复杂空间特征,如形状、大小等<sup>[19-20]</sup>。如式(5)所示。

$$THR^S_{DMP} = |\overline{THR^{S+\Delta S}} - \overline{THR^S}| \quad (5)$$

式中: $\Delta s$ 是移动步长。

在 DMP 中取平均得到 MBI 如式(6),即为形态学建筑物指数。

$$MBI = \overline{mean}_s(THR_{DMP}) \quad (6)$$

综上,两景影像分别提取特征如表 1 所示。

表 1 特征提取

特征	说明
原始光谱特征	红、绿、蓝三波段 原始光谱特征均为经过预处理后的值
纹理特征	Contrast、Entropy、Second Moment、Correlation、LBP 基于 GLCM 的纹理特征在 0°、45°、90°和 135°方向上取平均,在 3×3 窗口内提取 LBP 特征
构造特征	VDVI、MBI VDVI 反映植被信息, MBI 反映建筑物信息

### 1.3 随机森林(Random Forest)

随机森林(Random Forest)是一种基于决策树结构集成学习的方式,结合了 Bagging 算法(Bootstrap aggregating,引导聚集算法)和随机子空间理论,集成众多决策树进行预测,通过各个决策树的预测值进行平均或投票,得到最终的预测结果<sup>[21]</sup>。其是一个 Bagging 算法的扩展应用,在以决策树为基础进行集成的基础上引入了随机属性,使最终集成的泛化性能得到加强。

随机森林首先采用基于自展法(Bootstrap)重采样,产生多个训练集;由每个自助数据集生成一棵决策树,由于采用了 Bagging 算法采样的自助数据集仅包含部分原始训练数据,将没有被 Bagging 采用的数据称为袋外(out-of-bag, OOB)数据,把 OOB 数据用生成的决策树进行预测,对每个 OOB 数据的预测结果错误率进行统计,得到的平均错误率即为随机森林的错误估计率<sup>[22-23]</sup>。而 OOB 误差估计作为泛化误差估计的一个组成部分,相关研究表明其可以取代测试集进行误差估计。同时由于随机森林抽取样本的随机性,OOB 数据作为评估学习器误差的指标,在选择不同特征时有不同的准确率,因此可以进行特征重要性的排序。

随机森林整体流程如图 2 所示。

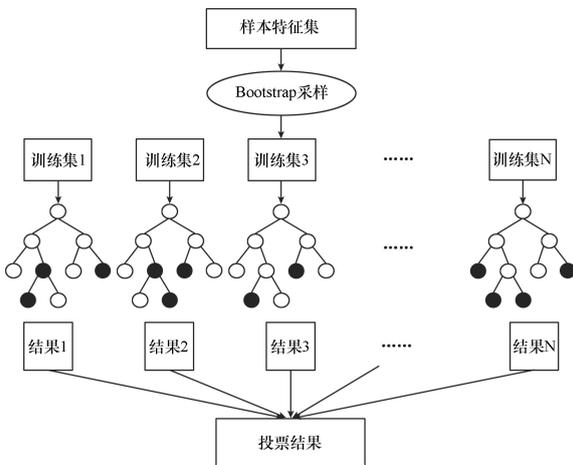


图 2 随机森林流程

### 1.4 极端梯度提升(XGBoost)

极端梯度提升(eXtreme Gradient Boosting, XGBoost)<sup>[24]</sup>是梯度提升决策树(Gradient Boosting Decision Tree, GBDT)的改进型算法,不同于

Random Forests 的 Bagging 集成学习,其采用 Boosting 集成学习方式,有多个具有关联性的决策树进行决策。XGBoost 将损失函数进行泰勒多项式的二次展开,其目标函数相对于 GBDT 具有更高的准确度和更快地收敛速度<sup>[25]</sup>。XGBoost 模型如公式(7)所示。

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (7)$$

式中: $\hat{y}_i$  为某个样本的预测值; $K$  为决策树的个数; $F$  为所有可能的决策树; $f_k(x_i)$  为具体的决策树。

其目标函数如公式(8)所示。

$$\text{obj}(\theta) = \sum_i^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (8)$$

式中: $n$  为样本数; $y_i$  为样本真实值; $l$  为损失函数; $\Omega$  为抑制函数复杂度的正则化项。

采用 boosting 的方法进行优化,依次优化每一棵树的模型,在保留原有模型的基础上进行下一级的优化,如公式(9)所示。

$$\begin{aligned} \hat{y}_i^{(0)} &= 0 \\ \hat{y}_i^{(1)} &= f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i) \\ \hat{y}_i^{(2)} &= f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i) \\ &\dots \end{aligned} \quad (9)$$

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i)$$

式中: $\hat{y}_i^{(t)}$  为第  $t-1$  步模型给出的函数预测值; $f_t(x_i)$  为新加入的模型预测值。

最终树优化如公式(10)所示。

$$\begin{aligned} \text{obj}^{(t)} &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{i=1}^t \Omega(f_i) \\ &= \sum_{i=1}^n l[y_i, \hat{y}_i^{(t-1)} + f_t(x_i)] + \Omega(f_t) + c \end{aligned} \quad (10)$$

式中: $c$  为前  $t-1$  棵树的复杂度。

对函数进行泰勒二阶展开,如式(11)所示。

$$\begin{aligned} \text{obj}^{(t)} &= \sum_{i=1}^n \left[ l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] \\ &\quad + \Omega(f_t) + \text{constant} \end{aligned} \quad (11)$$

$$g_i = \partial_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)})$$

$$h_i = \partial_{\hat{y}_i^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)}) \quad (12)$$

最终优化的损失函数如下:

$$\sum_{i=1}^n \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (13)$$

式中: $g_i$  为损失函数一阶导数; $h_i$  为损失函数二阶导数。

$g_i$  和  $h_i$  是不依赖于损失函数的形式的,只要这个损失函数二次可微就可以了,后续在模型正则化的基础上即可实现 XGBoost 的训练。

XGBoost 可以通过计算相关特征在每棵树中的分裂次数赋以对应的权重,实现特征重要性的排序,如式(14)所示,特征  $j$  在整个模型中的重要性为特征在单棵树中重要度的平均值衡量。

$$\hat{J}_j^2 = \frac{1}{M} \sum_{m=1}^M \hat{J}_j^2(T_m) \quad (14)$$

式中: $\hat{J}_j^2$  为特征  $j$  的全局重要度; $M$  为整个模型中树的数量; $\hat{J}_j^2(T_m)$  为第  $m$  棵树的重要度,公式如下:

$$\hat{J}_j^2(T) = \sum_{i=1}^{L-1} i_i^2(v_i = j) \quad (15)$$

式中: $L$  为树的分裂次数; $v_i$  是和节点  $i$  相关联的特征; $i_i^2$  是节点分裂后平方损失的减少值。

### 1.5 精度评价

采用准确率(ACC)、漏检率(MA)和误检率(FA)3个指标进行变化检测的精度评价,其中准确率表示正确检测的像元(包括发生变化和未发生变化)占总像元的比例,漏检率表示发生变化但是没有检测出的像元占发生变化总像元的比例,误检率表示实际没有发生变化但是被错误检测成变化像元占未发生变化总像元的比例。三者计算公式如下:

$$ACC = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \quad (16)$$

$$MA = \frac{N_{FN}}{N_{TN} + N_{FN}} \quad (17)$$

$$FA = \frac{N_{FP}}{N_{TP} + N_{FP}} \quad (18)$$

式中: $N_{TP}$  为正确检测的变化像元数量; $N_{FP}$  为实际未变化但是检测为变化的像元数量; $N_{TN}$  为正确检测的未变化像元数量; $N_{FN}$  为实际变化但是检测为未变化的像元数量。

## 2 实验与结论

实验主要由3部分构成:①对两时相影像进行预处理并提取特征,除传统的光谱特征和纹理特征之外,考虑到本实验区域和实验数据的特点,加入人为构造的 VDDVI 和 MBI 指数,分别反映植被变化

信息和建筑物的变化信息;②构建特征差异影像并选取样本,选择传统的差值法对各特征构建差异影像,结合原始影像选择变化和未变化的样本,开展基于像素级别的变化检测方法研究;③分别利用随机森林(Random Forest)、极端梯度提升(XGBoost)两种集成学习方式和传统的机器学习 SVM 进行变化检测试验,与经典变化检测方法(CVA 和 IR-MAD)在精度和效率上进行对比分析。整体流程如图3所示。

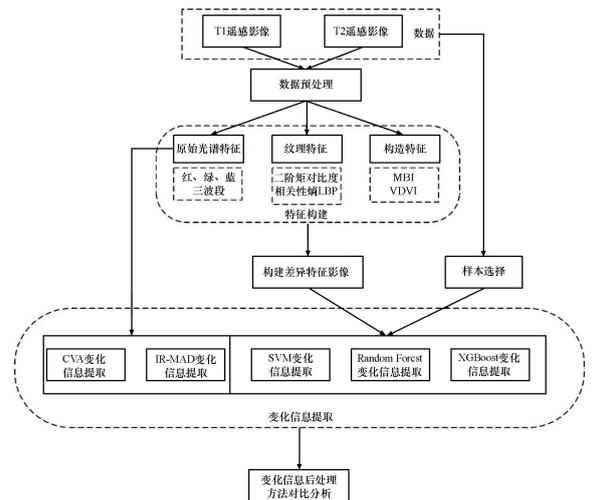


图3 整体流程

分别采用 Random Forest、XGBoost 和 SVM 算法进行训练,其中为评估随机森林中决策树的数量对最终变化检测结果的影响,对[10,90]区间范围内以5为动态变化步长进行实验,计算30次 OOB 准确率的平均值进行可视化,如图4所示,当决策树个数达到60时,随机森林的 OOB 准确率达到98.6%,后续继续增加决策树个数,OOB 准确率并不会提升,同时模型训练效率会降低,因此在实验中设置决策树个数为60是合理的。

为验证人工选取的 VDDVI 和 MBI 特征在变化检测中的作用,通过 Random Forest 和 XGBoost 进行特征的重要性排序,结果如图5所示,特征差异对随机树森林模型的影响由大到小依次为:B3(蓝光波段)、B1(红光波段)、MBI、VDDVI、Contrast、B2(绿光波段)、Entropy、Second Moment、LBP 和 Correlation。在 XGB 模型中,MBI 特征重要性仅次于 B3(蓝光波段),VDDVI 特征重要程度较大部分纹理特

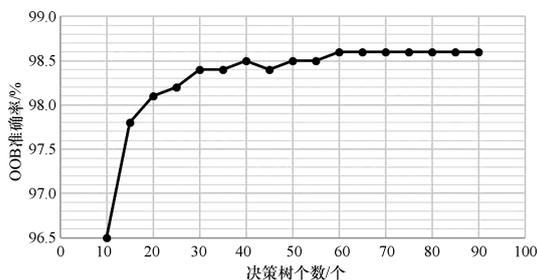
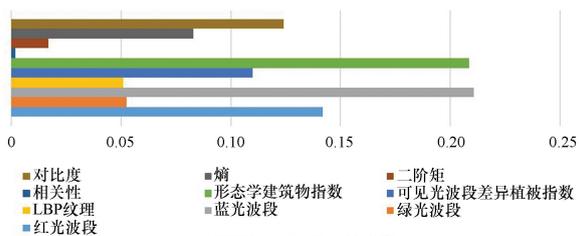
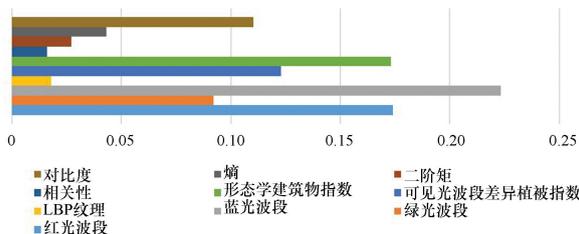


图 4 OOB 准确率

征更高,因此人为构造的 VDVI 和 MBI 特征在该地区的变化检测中有效。



(a)XGBoost特征重要性排序



(b)random Forest特征重要性排序

图 5 特征重要性

为后续进行算法的比较分析,利用 XGBoost 进行训练时保持决策树个数与随机森林中决策树个数一致。利用 SVM 进行训练时,采用五折交叉检验的方式,确定最优化参数  $C = 10$ ,核函数选择 rbf。

传统的变化检测主要有变化矢量分析(CVA)、迭代加权多元检测(IR-MAD)等方式,针对实验区域,采用两种传统方式进行检测。其中 CVA 变化检测需要阈值分割,而阈值选取对最后的精度评定有重要影响,分别采用 Otsu's、Tsai's 和 Kittler's 自适应阈值分割算法进行图像的二值化分割,避免人为主观性。在 IR-MAD 中,变化阈值设置为 0.001,迭代至 42 次时阈值变化小于设定值。

以人工提取的变化信息作为参考影像,对上述算法进行评价,结果如表 2 所示。

表 2 变化检测精度评价

检测方法	精度/%	漏检率/%	误检率/%	时间/s
Random Forest	88.81	21.72	10.95	24.88
XGBoost	94.02	34.04	5.35	5.12
SVM	95.29	54.68	3.57	163.16
CVA-Otsu's	45.72	54.90	27.17	—
CVA-Tsai's	93.27	52.42	5.68	—
CVA-Kittler's	96.86	73.10	1.55	—
IR-MAD	89.83	76.81	8.65	—

通过上述几种方法的对比可以得到:

(1)在传统的变化检测方法中,检测质量严重依赖阈值的确定,如 CVA 变化检测,通过不同的阈值确定方式得到的精度相差较大,基于 Tasi's 的阈值分割方式漏检率明显小于其他两种阈值分割方式(Otsu's 和 Kittler's),误检率处于合理区间,因此在 CVA-Tsai's 变化检测较其余方式(包括 IR-MAD)更具优势。

(2)3 种机器学习变化检测对比 CVA-Tsai's 优势明显,Random Forest 相对于 CVA-Tsai's 的 52.42% 的漏检率明显降低,同时误检率处于较合理的区间,其余两种机器学习方式(XGBoost 和 SVM)在精度、漏检率和误检率上明显优于 CVA-Tsai's。

(3)XGBoost 变化检测方法的精度、漏检率、误检率和效率明显优于 Random Forest 方式,相对于传统的机器学习 SVM 方法,其漏检率大幅下降近 20%,误检率虽有上升,但其效率较 SVM 提升 30 余倍。综合来看,XGBoost 变化检测方法相对于其他两种机器学习方式优势明显。

需要指出的是以上方法都是基于像素级别的变化检测,检测结果中存在较多椒盐噪声,因此通过聚类和滤波等后处理消除噪声。

### 3 结束语

本研究以沿海地区某处在建港口为实验区,在变化复杂情况下进行了变化检测实验,利用原始光谱特征、纹理特征和人为构造的 VDVI、MBI 指数构建差异影像,分别使用两种集成学习方式进行了变化检测实验,并与传统的 SVM 方法和经典变化检测方法进行了对比。

经实验验证,集成学习方式能够实现自动化的

变化信息提取,其效率远远超过传统的 SVM 方法,并且漏检率和误检率等指标优于经典的变化检测方式,在实验中,XGBoost 相对于 Random Forest 算法实现了较好的效果,同时经实验验证,人为构造的两种特征在进行变化信息提取时均起到比传统特征更加重要的作用。

需要指出的是,目前实际变化检测工作中依旧以人工判断提取变化区域为主,本研究方法可作为辅助参考,提升作业效率;由于本研究方法属于像素级别的变化检测,变化检测结果中存在大量椒盐噪声,后续在面向对象的基础上实现准确、自动化的变化检测是进一步研究的方向。

## 参考文献

- [1] 潘德炉. 遥感技术在海岸带环境监测与管理中的作用[EB/OL]. (2006-06-19)[2020-06-03]. [http://www.igsnr.ac.cn/xwzx/kydt/200606/t20060619\\_1813828.html](http://www.igsnr.ac.cn/xwzx/kydt/200606/t20060619_1813828.html).
- [2] 李清泉, 卢艺, 胡水波, 等. 海岸带地理环境遥感监测综述[J]. 遥感学报, 2016, 20(5): 1216-1229.
- [3] 李德仁. 利用遥感影像进行变化检测[J]. 武汉大学学报(信息科学版), 2003(S1): 7-12.
- [4] 魏立飞, 钟燕飞, 张良培, 等. 遥感影像融合的自适应变化检测[J]. 遥感学报, 2010, 14(6): 1196-1211.
- [5] CHEHATA N, ORNY C, BOUKIR S, et al. Object-based forest change detection using high resolution satellite images [C]// STILLA U, ROTTENSTEINER F, MAYER H, et al. Photogrammetric image analysis. Munich, Germany: International Society for Photogrammetry and Remote Sensing, 2011.
- [6] 张鑫龙, 陈秀芳, 李飞, 等. 高分辨率遥感影像的深度学习变化检测方法[J]. 测绘学报, 2017, 46(8): 999-1008.
- [7] DU B, RU L X, WU C, et al. Unsupervised Deep Slow Feature Analysis for Change Detection in Multi-Temporal Remote Sensing Images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(12): 9976-9992.
- [8] 李亮, 舒宁, 王凯, 等. 融合多特征的遥感影像变化检测方法[J]. 测绘学报, 2014, 43(9): 945-953+959.
- [9] 王志盼, 雷帆, 尤淑撑, 等. 单类分类框架下的高分辨率遥感影像建筑物变化检测算法[J]. 武汉大学学报(信息科学版), 2020, 45(10): 1610-1618.
- [10] 白洋. 基于核典型相关分析的遥感图像辐射归一化研究[D]. 北京: 中国科学院大学(中国科学院遥感与数字地球研究所), 2018.
- [11] 郭丽峰, 高小红, 亢健, 等. 伪不变特征法在遥感影像归一化处理中的应用[J]. 遥感技术与应用, 2009, 24(5): 588-595.
- [12] 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, 2014, 16(4): 663-677.
- [13] HARALICK R M, SHANMUGAM K. Texture features for image classification[J]. Studies in Media and Communication, 1973, SMC-3(6): 610-621.
- [14] ULABY FT, KOUYATE F, BRISCO B, et al. Textural information in SAR Images[J]. IEEE Transactions on Geoscience and Remote Sensing, 1986, 24(2): 235-245.
- [15] NARESH Y G, NAGENDRASWAMY H S. Classification of medicinal plants: An approach using modified LBP with Naresh YG, Nagendraswamy HS. Classification of medicinal plants: An approach using modified LBP with symbolic representation[J]. Neurocomputing, 2016, 173(3): 1789-1797.
- [16] 罗亚, 徐建华, 岳文泽, 等. 植被指数在城市绿地信息提取中的比较研究[J]. 遥感技术与应用, 2006, 21(3): 212-219.
- [17] 汪小钦, 王苗苗, 王绍强, 等. 基于可见光波段无人机遥感的植被信息提取[J]. 农业工程学报, 2015, 31(5): 152-157+159+158.
- [18] HUANG X, ZHANG L. A Multidirectional and Multiscale Morphological Index for Automatic Building Extraction from Multispectral GeoEye-1 Imagery[J]. Photogrammetric Engineering & Remote Sensing, 2011, 77(7): 721-732.
- [19] ACQUA F D, GAMBA P, FERRARI A. Exploiting spectral and spatial information for classifying hyperspectral data in urban areas [C]// CARR K, MEYER R. 2003 IEEE International Geoscience and Remote Sensing Symposium Proceedings. Toulouse, France: Institute of Electrical and Electronics Engineers Inc, 2003.
- [20] PESARESI M, BENEDIKTSSON J A. A new approach for the morphological segmentation of high resolution satellite imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(2): 309-320.
- [21] 冯文卿, 睦海刚, 涂继辉, 等. 高分辨率遥感影像的随机森林变化检测方法[J]. 测绘学报, 2017, 46(11): 1880-1890.
- [22] 顾海燕, 闫利, 李海涛, 等. 基于随机森林的地理要素面向对象自动解译方法[J]. 武汉大学学报(信息科学版), 2016, 41(2): 228-234.
- [23] 郭玉宝, 池天河, 彭玲, 等. 利用随机森林的高分一号遥感数据进行城市用地分类[J]. 测绘通报, 2016(5): 73-76.
- [24] CHEN T, GUESTRIN C. XGBoost: A scalable tree boosting system [C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016: 785-794.
- [25] 岳鹏, 侯凌燕, 杨大利, 等. 基于 XGBoost 特征选择的疾病诊断 XLC-Stacking 方法[J]. 计算机工程与应用, 2020, 56(17): 141-146.