

doi: 10. 6046/zrzyg. 2022354

引用格式: 刘涵薇,陈富龙,廖亚奥. 明长城(北京段)遥感动态监测与影响驱动分析[J]. 自然资源遥感,2023,35(4):255 – 263. (Liu H W, Chen F L. Remote sensing dynamic monitoring and driving factor analysis for the Beijing section of Ming Great Wall [J]. Remote Sensing for Natural Resources, 2023, 35(4): 255 – 263.)

明长城(北京段)遥感动态监测与影响驱动分析

刘涵薇^{1,2,3}, 陈富龙^{1,2}, 廖亚奥⁴

(1. 中国科学院空天信息创新研究院数字地球重点实验室,北京 100094; 2. 可持续发展大数据国际研究中心,北京 100094; 3. 中国科学院大学,北京 100049; 4. 中国地质大学(北京),北京 100083)

摘要: 长城文化带经济生态协调发展和文化景观保护是区域社会可持续发展的重要内容。面向大型线性文化遗产一体化监测与评估现实需求,提出了一种集成面向对象变化向量分析和 U-net 深度学习的遥感动态监测方法;通过对分类散点噪声的抑制和重点区域环境要素的精准动态刻画,实现了结合社会经济数据与遥感变化检测的文化景观变迁驱动影响因子诠释与信息挖掘。实验以明长城(北京段)为研究对象,使用 2015—2020 年高分二号(GF-2)2 m 分辨率的融合图像,通过多尺度分割、变化向量分析提取、U-net 图像分类等方法,对其景观廊道进行地表要素遥感变化检测和土地覆盖变化矩阵定量分析。结果表明:明长城(北京段)文化带土地覆盖变化率为 0.098%,主要表现为裸土、耕地等向林地转化以及人工用地的增加;同时,文化带生态环境呈正向发展,保护态势整体良好。研究结果可为明长城(北京段)生态环境协调发展和文化景观可持续保护提供技术支持。

关键词: 明长城;深度学习;变化检测;土地覆盖变化率;时空分析

中图法分类号: TP 79 **文献标志码:** A **文章编号:** 2097-034X(2023)04-0255-09

0 引言

长城作为我国首个列入世界文化遗产名录的遗产项目,承载着中华民族“创造、奋斗、团结与梦想”的伟大精神。《北京城市总体规划(2016—2035年)》提出,北京长城文化带总面积 4 929.29 km²,为历史文化名城保护体系中的重要组成部分,亦是全国文化中心建设的重要内容。注重保护其自然生态系统的原真性及完整性,对北部生态涵养功能区建设、北京历史文化脉络探索、京津冀一体化战略协同发展都极为重要^[1]。开展线性遗产文化带环境要素动态变化及其驱动因子研究,能够科学掌握其保护现状和发展态势,在监测评估中更好地落实自然生态系统的整体保护,为文化带经济、生态协调发展与遗产文化景观可持续保护利用提供科学数据和技术手段。

明长城(北京段)景观廊道范围广,传统踏勘方法耗时耗力。卫星遥感技术具备宏观、客观、快速和精准等观测优势,在大型线性文化遗产景观廊道环

境要素一体化监测中具备应用潜力。遥感动态监测方法历经了数理统计^[2]、面向对象^[3-4]、融合遥感大数据和机器学习^[5-6]的技术革新过程。当前,深度学习方法为遥感科学与技术的纵深发展带来了新的生命力。该方法能规避人工主观性,依据损失函数自行抽取与任务最相关的特征;且学习模型具备一定迁移性和多场景应用能力^[7]。近年来,众学者对深度学习方法在遥感数据分析中的作用机制、面临挑战、具备优势和应用价值等进行了深入探索^[8-9],提出了改进模型与算法^[10-11],并成功应用于城市绿地分类、大型遥感建筑物变化检测^[12-14]以及文化遗产环境要素监测分析^[15-17]等多种领域。然而,该方法在大型线性文化遗产景观廊道整体性监测与方法适应性评估等方面的工作仍较为匮乏。综合考虑明长城(北京段)文化带监测评估工作相对不足和环境要素变迁机制相对不明的现状,本文选取该文化带为实验对象,使用提出的集成面向对象变化向量分析和 U-net 深度学习遥感动态监测方法开展应用研究,旨在厘清 2015—2020 年度明长城(北京段)文化带土地覆盖类型变化趋势及其与社会经济

收稿日期: 2022-08-30; 修订日期: 2022-09-22

基金项目: 国家重点研发计划国际合作重点专项“星载雷达干涉非侵入式文化遗产脆弱性监测与评估”(编号: 2017YFE0134400)和国家重点研发计划项目“不可移动文物自然灾害风险评估与应急处置研究”(编号: 2019YFC1520800)共同资助。

第一作者: 刘涵薇(1997-),女,硕士,研究方向为雷达遥感。Email: liuhanwei20@mails.ucas.ac.cn。

通信作者: 陈富龙(1980-),男,研究员,研究方向为雷达遥感文化遗产智能感知与保护。Email: chenfl@aircas.ac.cn。

之间的内在关联,进而为该文化带生态环境协调发展和文化景观可持续保护提供技术支持。

1 研究区概况及数据源

1.1 研究区概况

北京市(E 115.7°~117.4°,N 39.4°~41.6°),地处于华北平原的西北边缘,地势西北高、东南低,三面环山,东南部为一片缓缓向渤海倾斜的平原。海拔范围8~2 303 m,东邻天津,南与河北交界。北京是全球拥有世界文化遗产(7处)最多的城市,也是全球首个拥有世界地质公园的首都城市。2020年全年接待旅游总人数达1.84亿人次;其中八达岭长城、慕田峪长城是该城市文化遗产重要名片。

明长城(北京段)总长约527 km,整体走势较连续。累计保存完整墙体比例约为12%,较完整约21%,存在损坏约67%,其保护工作仍有待加强。墙体周围环境廊道作为该文化遗产的核心监控范围,对于明长城本体的保护具有影响和承接作用。土地覆盖类型的变化可反映自然生态变迁及社会经济活动态势,对于其整体的监测评估和驱动机制挖掘极为重要。本文以明长城(北京段)位置及走向为基准、向两侧各扩充2 km的文化带为研究区域。该景观廊道处于北京市北部,西临军都山,北靠燕山山脉,蜿蜒跨越延庆、怀柔等多个区域,空间展布范围较大(图1)。



图1 明长城(北京段)文化带研究范围示意图
Fig.1 Schematic diagram of research area of the cultural belt of Beijing section of Ming Great Wall

1.2 数据源

覆盖明长城(北京段)的2015年和2020年2期高分二号(GF-2)图像,包含2 m分辨率全色和8 m分辨率多光谱(蓝、绿、红、近红外)波段。经过ISH融合增强处理,得到2 m分辨率多光谱(RGB)真彩色图像。

为了对明长城(北京段)文化带进行多维度的影响因子驱动分析,收集了相关年份各行业产值及

比例等社会经济数据(北京统计年鉴: <http://nj.tjj.beijing.gov.cn/nj/main/2021-tjnj/zk/indexch.htm>)。

2 研究方法

研究从GF-2图像及明长城展布范围出发,集成面向对象的变化向量分析(change vector analysis, CVA)掩模提取和U-net深度学习图像分类技术,对2015—2020年间明长城(北京段)文化带的环境要素进行遥感动态监测;进而通过对重点靶区的精准聚焦和土地覆盖变化矩阵的过程追溯,实现影响驱动因子的信息挖掘与科学诠释(图2)。




图2 明长城文化带遥感动态监测与影响因子驱动分析技术流程图
Fig.2 Technical flow chart of remote sensing dynamic monitoring and impact driven analysis of Ming Great Wall cultural belt

2.1 多尺度分割

将配准好的前后2个时相的图像叠置,组合成兼顾二者信息的多时相组合图像;采用多尺度分割算法对其进行分割,得到矢量斑块,作为后续变化区域掩模提取的尺度对象。分割中需要确定尺度因子、形状因子、紧致度以及各个波段所占权重大小等。为了能够将聚集的同质对象有效识别出来,在保证相邻图斑明显差异性的基础上,需要避免过度分割导致数据零碎^[18]。

由于分割结果难以做到与实际地物类别分离情况完全吻合,分割后需进一步进行斑块分离与合并。总体而言,分割参数的选用需要根据实际情况、影像分辨率、地物分布特点等优化选定。

2.2 变化向量分析

采用面向对象的CVA方法^[19],将前后2期数

据的斑块特征值构成特征矢量,设定基准图像(前时相)特征矢量为 X ,待检测图像(后时相)的特征矢量为 Y ,即

$$X = \begin{bmatrix} x_1 \\ x_1 \\ \cdots \\ x_n \end{bmatrix}, Y = \begin{bmatrix} y_1 \\ y_1 \\ \cdots \\ y_n \end{bmatrix}, \quad (1)$$

$$|\Delta C| = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \cdots + (x_n - y_n)^2}, \quad (3)$$

式中 $|\Delta C|$ 包含了从前-后时相数据各个特征值变化的总和,代表着 2 期图像的特征差异;其值越大,表明 2 期图像间的差别越大,即对应斑块土地覆盖类型变更概率越大;反之亦然。进而,可以根据计算的变化强度阈值,判定斑块变化属性。

2.3 深度学习图像分类

深度学习模拟人脑多层嵌套的神经系统,逐层进行数据特征的提取并学习其内在的规律特点,能够从样本中抽取更高层次的特征,为遥感图像的处理提供了更为智能化的方式。

卷积神经网络是根据输入/输出建立对应关系的网络模型,主要由提取特征的卷积层、浓缩数据量并过滤提取信息的池化层、整合类别区分信息的全连接层以及输入、输出层构成^[20]。而针对图像语义分割,该方法通过全卷积网络,确定遥感图像像素类别并保留其位置信息。

本文采取一种 U 形对称全卷积网络—U-net,最初由 Ronneberger 等^[21]提出。其体系结构主要分为 2 部分:编码器和解码器。编码器通过多个卷积层连续采样,得到不同的图像特征级别,在每次下采样之后,特征通道的数量也增加了一倍;由于最大池化层的存在,特征映射的大小也将逐级减小。解码器对顶层特征图进行多层反卷积,并在下采样过程中结合不同的特征层,将特征图恢复到原始输入图像大小,完成图像的端到端语义分割任务^[22]。

2.4 土地覆盖变化率计算及变化矩阵生成

假设前后 2 时相分别为 t_1 和 t_2 ,分类结果共有 m 种,则以灰度值 $0 \sim (m - 1)$ 代表各类别,将 2 时相结果进行差分:若像素值为 0,代表前后类别相同,未产生变化;若前后类别不同,则重新赋值为 1,代表发生变化。计算变化区域占总研究区的百分比即为变化率,即

$$\delta = n_{v=1} / (n_{v=0} + n_{v=1}), \quad (4)$$

式中: δ 为变化率; v 为灰度值; n 为像素个数。土地覆盖变化率综合反映自然过程及人为活动影响下地表覆盖变化的强度。

式中 n 为特征值数。
二者相减得到变化矢量 ΔX ,即

$$\Delta X = X - Y = \begin{bmatrix} x_1 - y_1 \\ x_2 - y_2 \\ \cdots \\ x_n - y_n \end{bmatrix}, \quad (2)$$

选取欧式距离值代表变化强度大小记为 $|\Delta C|$,即

变化矩阵由分类后各类别的转换情况构成,为 $m \times m$ 的矩阵,代表各类别转换的数量及占比情况,能够较为清晰地表达地表覆盖的转换过程。

3 实验及结果

3.1 变化区域掩模提取

为了方便 2 期数据对比处理以及综合考虑程序内存容量限制,将整体廊道通过棋盘分割方式,以 $5\,000 \times 5\,000$ 像素为基本单元,划定为 53 个区块(图 3),构成 2015 年和 2020 年 53 对区块影像。




图 3 明长城(北京段)文化带廊道影像分块示意图
Fig. 3 Image block diagram of cultural belt corridor along Beijing section of Ming Great Wall

将每对区块影像叠置,进行多尺度分割。根据研究区地物整体特征,设置尺度因子为 30,形状因子 0.1,紧致度 0.5,实现人工用地细节信息地精细分割。根据分割后的矢量文件,通过 CVA 算法提取差异较大的斑块,作为变化区域掩模图层输入。

3.2 深度学习遥感图像分类

3.2.1 样本制作及数量测试

依据已有土地利用分类体系标准,结合 GF-2 融合影像特征,选取人工用地、水体、林地、草地、耕地、裸地进行样本勾画和制作,以凸显和刻画明长城文化带环境要素地动态变化过程^[23]。选取全连接网络 U-net 模型,将大尺寸影像及标签图像切割为若干 256×256 像素样本集合,并通过旋转、翻转、改变对比度等方式对样本集进行增广,以提高模型学

习的鲁棒性。

通过控制样本数量对模型进行分类精度测试,分类精度性能对比如表 1 与图 4。

表 1 不同样本量对 U-net 模型分类精度的影响

Tab.1 Influence of different sample sizes on classification accuracy of U-net model				
量级	极少	少量	中等	大量
训练样本/个	1 227	7 362	49 710	53 020
测试样本/个	461	2 766	18 360	22 640
分类精度/%	50	75	84	86




图 4 不同样本量下 U-net 模型分类精度变化

Fig.4 Change of classification accuracy of U-net model under different sample sizes

从图 4 可以看出,分类精度整体随样本量的增加而提高;其次,当样本数量从前期的千级到万级跨越时,模型学习性能提升幅度明显;后期则随着样本量增加,精度提升呈现收敛趋势。将所制作的样本以 7:3 的比例进行训练样本和测试样本的分配,最终使用的学习样本数量为:2015 年训练样本 53 020 个,验证样本 22 640 个;2020 年训练样本 53 244 个,验证样本 22 788 个。本研究样本量在 7 万~8 万之间,可实现优于 85% 的分类准确度。

3.2.2 模型训练及预测

经过测试,设置 *batch_size* = 16,学习率为 0.000 1 时模型效果最佳,2 期模型训练精度及损失曲线如图 5。训练均在 5 轮内收敛且继续稳步提升。2015 年模型训练精度最高达 99.3%,验证精度达 97.1%,训练损失降至 0.024,验证损失降至 0.123。2020 年模型训练精度最高达 96.5%,验证精度达 96.8%,训练损失降至 0.223,验证损失降至 0.218。

针对整景或广覆盖遥感图像的处理,本文采用待分类图像分割批量预测和结果拼接的处理策略。CVA 变化掩模图层的输入,可使 U-net 深度学习




图 5 深度学习 U-net 模型训练精度曲线及损失曲线(2015 年和 2020 年)

Fig.5 Training accuracy curves and loss curves of deep learning U-net model (2015 and 2020)

聚焦预变化重点区域,在提升数据处理效率的基础上,进一步抑制基于像素处理的分类散斑噪声。在整个研究区生成 1 000 个随机验证点位,人工判别确定真值类别,对分类结果通过混淆矩阵分析精度(表 2、表 3)。结果显示:2015 年整体精度可达

86.40%,Kappa 系数为 0.66;2020 年整体精度可达 87.20%,Kappa 系数为 0.65;揭示了模型预测结果的鲁棒性以及研究区各类别面积占比变化的差异性。

表 2 明长城(北京段)影像 U-net 分类结果混淆矩阵(2015 年)

Tab.2 Confusion matrix of U-net classification results along the Beijing section of Ming Great Wall (2015)								
类别	人工用地	水体	林地	草地	耕地	裸地	总计	U_精度/%
人工用地	42	0	1	0	0	0	43	97.67
水体	0	10	1	0	0	0	11	90.91
林地	2	2	732	0	0	4	740	98.92
草地	0	0	5	4	0	0	9	44.44
耕地	1	0	44	3	73	37	158	46.20
裸地	0	0	0	0	36	3	39	7.69
总计	45	12	783	7	109	44	1 000	
P_精度/%	93.33	83.33	93.49	57.14	66.97	6.82		86.40
Kappa = 0.66								

表 3 明长城(北京段)影像 U-net 分类结果混淆矩阵(2020 年)

Tab.3 Confusion matrix of U-net classification results along the Beijing section of Ming Great Wall (2020)								
类别	人工用地	水体	林地	草地	耕地	裸地	总计	U_精度/%
人工用地	37	1	2	0	7	1	48	77.08
水体	0	11	0	0	0	0	11	100.00
林地	0	1	758	0	0	8	767	98.83
草地	0	0	0	1	0	0	1	100.00
耕地	4	0	45	2	62	41	154	40.26
裸地	1	0	1	0	14	3	19	15.79
总计	42	13	806	3	83	53	1 000	
P_精度/%	88.10	84.62	94.04	33.33	74.70	5.66		87.20
Kappa = 0.65								

3.3 景观廊道环境要素动态监测

研究区 GF-2 图像的获取时相对应作物成熟/收割生长周期,光谱特征与同时期的草地、耕地、裸地相似(同谱异物)。考虑这些土地覆盖类型与人为扰动相关度不大,故对其进行合并处理为“裸土耕地等”,与原“人工用地”、“水体”、“林地”生成 4

大土地覆盖类型。将重分类后的 2015 年和 2020 年度图像进行差分,得到文化带景观廊道土地覆盖变化图及其对应类型变更信息(图 6);子图 A—D 为放大后的典型转换类别。计算变化图斑比例得到土地覆盖总体变化率为:

$$\delta = 2\,229\,413 / (2\,229\,413 + 2\,280\,197\,447) = 0.098\% ,$$

(5)




图 6 明长城(北京段)2 km 文化带土地覆盖类型变化图

Fig.6 Land cover changes along the 2 km cultural belt of the Beijing section of Ming Great Wall

4 讨论与分析

4.1 深度学习与传统分类方法对比

为了验证所选模型的适用性与有效性,选取一处含多种地物类型的图像为示例,分别使用决策树(decision tree classifier, DTC)、支持向量机(support vector machine, SVM)、随机森林(random forest, RF)分类器与 U-net 进行对比试验;并随机选取 100 个点位对分类结果进行精度评价,结果见表 4。由图 7、图 8 分类对照结果可知,图像中裸地与耕地光谱差异较小,山体阴影造成林区易与水体混淆,即

表 4 DTC、SVM、RF 与 U-net 分类精度对比

Tab.4 Comparison of the classification accuracy of DTC, SVM, RF and U-net

分类器	DTC	SVM	RF	U-net
总体精度/%	65	70	72	86
Kappa	0.53	0.56	0.59	0.79

DTC、SVM、RF 分类器按光谱等特征进行土地覆盖分类,因同物异谱、异物同谱现象错分明显;而 U-net 模型能通过样本迁移,学习发现地物之间整体规律和语义信息,改善山体阴影等错分现象,类别完整性好,分类精度提升明显。




图 7 测试图像与 U-net 模型分类结果

Fig.7 Classification results of test image and U-net model




图 8 RF、DTC 和 SVM 分类结果

Fig.8 Classification results of RF, DTC and SVM

4.2 变化矩阵与影响因子驱动分析

统计各地表要素变化类型像素的数量与比例,得到类别变化矩阵(表 5)。

表 5 明长城(北京段)文化带 2015—2020 年土地覆盖变化矩阵

Tab.5 Change matrix of land cover in the cultural belt of Beijing section of the Ming Great Wall from 2015 to 2020

地类	人工用地	水体	林地	裸土耕地等
人工用地	—	5	264 019	132 763
水体	6 192	—	14 034	3 735
林地	244 862	3	—	239 076
裸土耕地等	547 943	2	776 645	—

由计算结果可知,总体变化率不到 0.1%;揭示明长城(北京段)所受影响较小。对变化矩阵作统计分析见图 9。由图 9 可知,地表要素的变化主要体现在裸土耕地等与人工用地、林地的转化,占比最大的为裸土耕地类别向林地转化,是森林覆盖面积

增加的表征,贡献文化带生态正向变化(占比 1/3)。其次是裸土耕地向人工用地转化(占比约 1/4),表现为自然空地、耕地等的人为占用,包括工业、商业以及居住用地的建设(图 10(a),(b)),揭示社会经济建设对生态环境的人为干预与破坏。同时占比




图 9 不同变化类别占比情况

Fig.9 Proportion of different change categories

约 12% 的人工用地拆除与环境整治情况,贡献林地面积增加和生态正向变化。林地与人工用地互为转化比例相当,占比约 11%; 另存在约 6% 的人工用地拆除或土地复耕。

同时研究也发现了少量伪变化标记,见图 10,




图 10 土地覆盖变化细节
Fig. 10 Details of land cover changes

对比 2015 年及 2020 年的各类经济数据(图 11),发现以养殖、种植、培育生物材料相关的第一产业逐年下降,对自然地类的使用率有所降低。而生产总值仍随经济发展而增长,含建筑土木、工业生产、房地产等的第二产业则呈现小比例提升,体现在土地覆盖中人工用地的征用或退还,与经济稳步发展整体协调。城市绿化覆盖(由 48.4% 变更至 49.0%)较为稳定,森林覆盖率达 41.6% 小幅增加至 44.4%,与变化矩阵中林地比例的上升情况相符。近年来,北京旅游人数缓慢增加(去除 2020 疫情重大社会事件因素),2015—2020 年旅游产业数据呈上升趋势,揭示对文化遗产保护与开发的更高要求。




图 11 各产值分布及各年份比率增长趋势
Fig. 11 Distribution of output value and growth trend ratio in recent years

综上所述,2015—2020 年明长城(北京段)文化带人工用地对裸土、林地等自然地类的侵占使用整体可控,生态环境保护与开发呈现正向发展态势。

5 结论

针对明长城大型线性文化遗产赋存环境一体化

图中每幅小图从左到右分别为 2015 年图像、2020 年图像和变化标记,如季节气候等变化引起的农作物的不同生长周期表征(如图 10(c) 为生长季与收割期差异);冬季水体表面结冰导致的高反射与常态深色水体的差异(图 10(d))。

监测和评估研究需求,本文提出了一种集成面向对象变化向量分析和 U-net 深度学习的遥感动态监测方法,开展 2015—2020 年时相文化带景观廊道土地覆盖遥感变化监测和社会经济影响驱动机制诊断,实验结果表明:

1) 明长城(北京段)文化带 2015—2020 年期间,土地覆盖变化率约千分之一,主要表现在裸土、耕地等向林地转化,以及人工用地部分占用;社会经济建设等扰动整体可控,文化带生态环境正向发展态势良好。

2) 针对 GF-2 真彩色图像中同物异谱、异物同谱等问题,深度学习图像分类相较于传统遥感分类方法具备优势,可以保留地物完整纹理和影像语义信息,获得更为精确的遥感地物分类结果。

3) 深度学习模型分类精度直接受制于样本数量,总体呈正比关系;但达到一定量级之后,精度改善缓慢并趋于饱和。使用 U-net 全连接网络进行语义分割需要保证样本与标签的全面对应,对典型性标签样本制作提出了更高要求。

总体来说,使用面向对象 CVA 变化掩模提取方法,辅助分类后变化检测可高效、精准获取土地覆盖变化靶区,抑制基于像素分类的散斑效应,便于时相间地物类别变化检测与变化矩阵定量分析。融合社会经济数据的遥感智能处理和信息解译,可以深层次挖掘、佐证变化驱动力因素,为文化带景观廊道环境要素动态变迁研究提供全新方案。未来我们将进一步细化样本类别,提升其广度与精度;针对遥感图像特征改进 U-net 模型结构,进一步提高模型的适配性与分类精度,为方法模型的普适性推广与复杂场景应用奠定技术基础。

参考文献 (References) :

[1] 汤羽扬,蔡 超,刘昭伟.北京市长城文化带保护发展规划编制回顾[C]//万里长城——庆祝中华人民共和国成立 70 周年论文集,2019:36 – 41.
Tang Y Y, Cai C, Liu Z Y. Into Beijing Great Wall culture belt protection and development[C]//The Great Wall: A collection of papers celebrating the 70th anniversary of the founding of the people's Republic of China, 2019:36 – 41.

[2] Lu D, Mausel P, Brondizio E, et al. Change detection techniques [J]. International Journal of Remote Sensing, 2004, 25 (12) : 2365 – 2401.

[3] Desclée B, Bogaert P, Defourny P. Forest change detection by statistical object – based method [J]. Remote Sensing of Environment, 2006, 102 (1 – 2) : 1 – 11.

[4] Huo C, Zhou Z, Lu H, et al. Fast object – level change detection for VHR images [J]. IEEE Geoscience & Remote Sensing Letters, 2010, 7 (1) : 118 – 122.

[5] Li P, Xu H. Land – cover change detection using one – class support vector machine [J]. Photogrammetric Engineering & Remote Sensing, 2010, 76 (3) : 255 – 263.

[6] Duro D C, Franklin S E, Dubé M G. A comparison of pixel – based and object – based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT – 5 HRG imagery [J]. Remote Sensing of Environment, 2012, 118 (6) : 259 – 272.

[7] 冯权洸,牛博文,朱德海,等.土地利用/覆被深度学习遥感分类研究综述[J].农业机械学报,2022,53(3):1 – 17.
Feng Q L, Niu B W, Zhu D H, et al. Review for deep learning in land use and land cover remote sensing classification [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53 (3) : 1 – 17.

[8] Zhang L, Zhang L, Bo D. Deep Learning for remote sensing data: A technical tutorial on the state of the art [J]. IEEE Geoscience and Remote Sensing Magazine, 2016, 4 (2) : 22 – 40.

[9] Zhu X X, Tuia D, Mou L, et al. Deep learning in remote sensing: A comprehensive review and list of resources [J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5 (4) : 8 – 36.

[10] 袁 伟,周 甜,奚宗顺,等. MUNet: 一种多尺度自适应的遥感语义分割深度学习网络 [J]. 测绘科学技术学报, 2020, 37 (6) : 581 – 588.
Yuan W, Zhou T, Xi Z S, et al. MUNet: A multi – branch adaptive deep learning network for remote sensing image semantic segmentation [J]. Journal of Geomatics Science and Technology, 2020, 37 (6) : 581 – 588.

[11] 李国清,柏永青,杨 轩,等.基于深度学习的高分辨率遥感影像土地覆盖自动分类方法[J].地球信息科学学报,2021,23(9):1690 – 1704.
Li G Q, Bai Y Q, Yang X, et al. Automatic deep learning land cover classification methods of high – resolution remotely sensed images [J]. Journal of Geo – information Science, 2021, 23 (9) : 1690 – 1704.

[12] 徐知宇,周 艺,王世新,等.面向 GF – 2 遥感影像的 U – Net 城市绿地分类[J].中国图象图形学报,2021,26(3):700 – 713.
Xu Z Y, Zhou Y, Wang S X, et al. U – Net for urban green space classification in Gaofen – 2 remote sensing images [J]. Journal of Image and Graphics, 2021, 26 (3) : 700 – 713.

[13] 韩 星,韩 玲,李良志,等.基于深度学习的高分辨率遥感图像建筑物变化检测[J].激光与光电子学进展,2022,59(10):55 – 63.
Han X, Han L, Li L Z, et al. Building change detection in high – resolution remote – sensing images based on deep learning [J]. Laser & Optoelectronics Progress, 2022, 59 (10) : 55 – 63.

[14] 马晓宇,张 新,刘吉磊,等.基于深度学习的中国边境地区城市发展与安防研究 [J]. 自然资源遥感, 2022, 34 (2) : 231 – 241. doi:10. 6046/zrzyyg. 2021157.
Ma X Y, Zhang X, Liu J L, et al. Research on urban development and security in border areas of China based on deep learning [J]. Remote Sensing for Natural Resources, 2022, 34 (2) : 231 – 241. doi:10. 6046/zrzyyg. 2021157.

[15] Thuestad A E, Tømmervik H, Solbø S A. Assessing the impact of human activity on cultural heritage in Svalbard: A remote sensing study of London [J]. The Polar Journal, 2015, 5 (2) : 428 – 445.

[16] Elfadaly A, Attia W, Qelichi M M, et al. Management of cultural heritage sites using remote sensing indices and spatial analysis techniques [J]. Surveys in Geophysical, 2018, 39 (12) : 1347 – 1377.

[17] 王臣立,徐 丹,林文鹏.红河哈尼梯田世界文化景观遗产的遥感监测与土地覆盖变化[J].生态环境学报,2021,30(2):233 – 241.
Wang C L, Xu D, Lin W P. Remote sensing monitoring and land cover change of the world cultural landscape heritage in Honghe Hani Terrace, China [J]. Ecology and Environmental Sciences, 2021, 30 (2) : 233 – 241.

[18] 毛 宁,刘慧平,刘湘平,等.基于 RMNE 方法的多尺度分割最优分割尺度选取 [J]. 国土资源遥感, 2019, 31 (2) : 10 – 16. doi:10. 6046/gtzyyg. 2019. 02. 02.
Mao N, Liu H P, Liu X P, et al. Optimal scale selection for multi – scale segmentation based on RMNE method [J]. Remote Sensing for Natural Resources, 2019, 31 (2) : 10 – 16. doi: 10. 6046/gtzyyg. 2019. 02. 02.

[19] 王晓慧,谭炳香,李世明,等.基于面向对象多特征变化向量分析法的森林资源变化检测 [J]. 林业科学研究, 2021, 34 (1) : 98 – 105.
Wang X H, Tan B X, Li S M, et al. Object – oriented forest change detection based on multi – feature change vector analysis [J]. Forest Research, 2021, 34 (1) : 98 – 105.

[20] Maggiori E, Tarabalka Y, Charpiat G, et al. Fully convolutional neural networks for remote sensing image classification [C]//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing, China. IEEE, 2016:5071 – 5074.

[21] Ronneberger O, Fischer P, Brox T. U – Net: Convolutional networks for biomedical image segmentation [J]. International Conference on Medical Image Computing and Computer – Assisted Intervention, Cham: Springer, 2015, 18 (9351) : 234 – 241.

[22] Zhao X, Yuan Y, Song M, et al. Use of unmanned aerial vehicle imagery and deep learning unet to extract rice lodging [J]. Sensors (Basel, Switzerland), 2019, 19 (18) : 3859 – 3872.

[23] 杨子生,杨诗琴,杨人懿,等.基于利用视角的土地资源分类方法探讨 [J]. 资源科学, 2021, 43 (11) : 2173 – 2191.
Yang Z S, Yang S Q, Yang R Y, et al. Classification method of land resources based on land use perspective [J]. Resources Science, 2021, 43 (11) : 2173 – 2191.

Remote sensing dynamic monitoring and driving factor analysis
for the Beijing section of Ming Great Wall

LIU Hanwei^{1,2,3}, CHEN Fulong^{1,2}, LIAO Yaa⁴

(1. Key Laboratory Digital Earth Science, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China; 2. International Research Center of Big Data for Sustainable Development Goals, Beijing 100094, China; 3. University of Chinese Academy of Sciences, Beijing 100049, China; 4. China University of Geosciences, Beijing 100083, China)

Abstract: The coordinated economic and ecological development and the cultural landscape preservation of the Great Wall cultural zone are crucial for regional social sustainability. To meet the need for integrated monitoring and evaluation of large – scale linear cultural heritage, this study proposed a remote sensing dynamic monitoring method that integrates object – oriented change vector analysis and U – net deep learning. Based on the suppression of classified scattered noise and the accurate dynamic description of key regional environmental components, this study achieved the interpretation and information mining of the factors driving cultural landscape changes by combining socio – economic data and remote sensing change detection. Building on the 2 – m – resolution GF – 2 fused images from 2015 to 2020, the Beijing section of Ming Great Wall was examined through remote sensing change detection of surface elements and quantitative analysis of the land cover change matrix for its landscape corridor using methods including multiresolution segmentation, change vector analysis and extraction, and U – net image classification. The study reveals that the land cover along the Beijing section of Ming Great Wall cultural zone yielded a change rate of 0.098%, primarily manifested in the shift from bare land and farmland to forests and the growth of artificial land. Meanwhile, the ecological environment of the cultural zone exhibited positive development and an overall favorable protection state. The research results will provide technical support for the coordinated economic and ecological development and the sustainable preservation of the cultural landscape along the Beijing section of Ming Great Wall.

Keywords: Ming Great Wall; deep learning; change detection; land cover change rate; spatio – temporal analysis
(责任编辑: 李 瑜)