

YAN Yan, WU Ling, LI Junji, ZHAO Yuxin, YE Xin. Forest Disturbance Attribution under Small Sample Conditions Based on Confidence Learning Mutual Guidance Framework (in Chinese). *Chinese Journal of Space Science*, 2025, 45(2): 397–412. CSTR:32142.14.cjss.2024-0146. DOI:10.11728/cjss2025.02.2024-0146

基于置信学习互导框架的小样本条件下森林扰动类型遥感分类*

严 燕¹ 吴 伶¹ 李军集^{1,2}
赵于鑫¹ 叶 昕³

1(中国地质大学(北京) 信息工程学院 北京 100083)

2(广西壮族自治区林业科学研究院 南宁 530002)

3(中国农业大学信息与电气工程学院 北京 100083)

摘 要 遥感技术作为地球系统和空间信息科学研究的核心手段,提高了人类对地球系统变化的理解,而开展地表重要组成部分——森林生态系统的扰动监测与分类研究可更精准高效。但受限于样本标注繁重和变化稀疏限制标注数量。本研究提出基于置信学习互导框架的小样本条件下森林扰动类型分类方法。利用 2000—2021 年 Landsat 数据与连续变化检测与分类 (Continuous Change Detection and Classification, CCDC) 算法检测森林扰动获得大量未标注数据,结合少量样本及基于随机森林 (Random Forest, RF) 和梯度提升 (Categorical Boosting, CatBoost) 分类器构建的互导框架,以迭代方式通过置信学习从未标注数据中筛选高置信度数据,扩充对方标注样本集,互相指导分类,进而提升分类精度。结果表明,该方法总体分类精度达 91.4%,较单一分类器提升 5%,在小样本条件下表现出优异性能,为森林扰动类型分类研究提供了高效、可靠的解决方案。

关键词 小样本, 置信学习, 互导框架, 森林扰动分类

中图分类号 TP79, P407

Forest Disturbance Attribution under Small Sample Conditions Based on Confidence Learning Mutual Guidance Framework

YAN Yan¹ WU Ling¹ LI Junji^{1,2}
ZHAO Yuxin¹ YE Xin³

1(School of Information Engineering, China University of Geosciences (Beijing), Beijing 100083)

2(Guangxi Forestry Research Institute, Nanning 530002)

3(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083)

* 北京市科学技术协会青年人才托举工程项目资助 (BYESS2023441)

2024-10-30 收到原稿, 2025-02-15 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

Abstract As the core technical means for human beings to carry out scientific research on the Earth system and the application of spatial information in multiple fields, remote sensing technology has comprehensively improved human beings' understanding of the complex process of changes in the Earth system, and the use of remote sensing technology with spatial and temporal continuity to carry out disturbance monitoring and classification research on forest ecosystems, which are important components of the Earth's land surface, can be more accurate and efficient. The use of remote sensing technology with spatial and temporal continuity to monitor and classify disturbances in forest ecosystems, an important component of the Earth's land surface, can be more accurate and efficient. However, Forest disturbance attribution requires a large number of disturbance type samples, and the laborious manual labeling of high-quality samples and the sparseness of the change region itself limit the number of labelable disturbance samples. In this study, we propose a forest disturbance attribution method under small sample conditions based on the confidence learning mutual guidance framework. In this study, we first used Landsat long time-series remote sensing data to detect forest disturbances between 2000 and 2021 based on the Continuous Change Detection and Classification (CCDC) algorithm to obtain a large amount of unlabeled disturbance data, and then used a small number of manually labeled samples and the mutual guidance framework constructed with Random Forest (RF) and Categorical Boosting (CatBoost) classifiers to iteratively filter high-confidence data from the unlabeled disturbance data through confidence learning, expanding the labeled sample size of each other's classifiers, and then guided each other's classifications to improve the classification accuracy of forest disturbance attribution. The results show that the overall accuracy of forest disturbance attribution based on the confidence learning mutual guidance framework is 91.4%. Compared with results using only a single classifier, the accuracy is improved by 5%. The method demonstrates excellent performance under small sample conditions and provides an efficient and reliable solution for forest disturbance type classification research.

Key words Small sample, Confidence learning, Mutual guidance framework, Forest disturbance attribution

0 引言

地球陆表生态系统变化及其驱动力分析是空间地球科学对地探索的核心问题之一^[1]. 森林生态系统是陆表生态系统的重要组成部分, 具有调节碳、水循环平衡, 维护生态系统多样性以及减缓气候变化的功能^[2-5]. 森林扰动是森林生态系统动态变化的重要过程^[6-8], 通过破坏森林的组成结构, 弱化生态服务能力, 降低森林资源的可用性^[9-11], 对森林碳储/汇产生影响^[12]. 不同森林扰动类型 (如砍伐、火灾以及道路建设等) 导致森林生长状态、林分物种组成、结构和功能的变化存在差异^[13,14]. 此外, 不同区域、不同时期占主导地位的森林扰动类型也可能不同. 因此, 有关扰动类型的发生和分布信息对于评估碳平衡^[13]、对生物多样性的影响^[15] 以及经济后果^[16] 非常重要.

作为一门建立在空间科学基础上的综合性技术, 遥感技术具有大范围、连续性观测地球表层的优势,

其被广泛应用于森林生态系统变化及其驱动力 (变化类型分类) 分析等生态监测领域. 传统的基于遥感技术的森林扰动类型分类, 如目视解译^[17] 不仅高度依赖专家知识且需要花费较高的时间成本, 因此不适合用于大面积多种森林扰动类型的研究. 而美国地质调查局 (United States Geological Survey, USGS) 提供的 Landsat 长时序影像具有较高的空间分辨率和丰富的森林历史信息, 促进了森林扰动类型分类方法的发展^[6,18-22]. 目前, 针对森林扰动类型分类研究的方法主要分为直接法和两阶段法^[23,24]. 直接法基于扰动分类的敏感特征, 结合先验知识, 借助机器学习算法 (如随机森林、决策树等) 同步进行扰动检测与分类^[25-27]. 两阶段法首先基于变化检测敏感特征, 利用变化检测算法, 例如 LandTrendr (Landsat-based Detection of Trends in Disturbance and Recovery), VCT (Vegetation Change Tracker), BFAST (Breaks For Additive Season and Trend), CCDC (Continuous Change

Detection and Classification) 等, 进行扰动检测, 再对扰动类型进行分类^[7,21-23,27-29]. 已有研究所用特征多使用遥感影像的原始波段或植被指数. 常用的植被指数包括归一化植被指数 (Normalized Difference Vegetation Index, NDVI)^[30]、归一化水指数 (Normalized Difference Water Index, NDWI)^[31]、归一化差分分数指数 (Normalized Difference Fraction Index, NDFI)^[32]、归一化燃烧率 (Normalized Burn Ratio, NBR)^[21] 和缨帽指数 (Tasseled Cap, TC)^[28], 包括亮度 (Tasseled Cap Brightness, TCB)、绿度 (Tasseled Cap Greenness, TCG) 和湿度 (Tasseled Cap Wetness, TCW). 这些指数被证明能有效区分扰动类型, 其中, NBR 的变化通常用于区分火灾和砍伐^[33], TC 的变化常用于表征植被变化, 特别是与森林有关的变化^[34,35].

目前, 针对森林扰动类型分类研究的方法均需要借助大量扰动类型样本构建分类模型. 现有研究通过历史记录资料、高分影像、实地调查等各种途径人工判读大量样本数据^[10,17,21]. 例如, Li 等^[20] 基于谷歌地球高分辨率影像目视解译, 采集了 1708 个斑块样本, 其中 632 个野火扰动样本, 345 个砍伐样本, 731 个人工经济林样本. 然而, 森林扰动数据采集过程中存在

的高质量样本人工标注工作量繁重、变化区域本身稀疏、特定扰动类型发生概率低问题, 限制了可标注变化样本的数量, 造成小样本对扰动特征代表性差, 从而导致分类效果不佳.

研究提出一种基于置信学习互导框架的小样本条件下森林扰动类型分类方法. 利用 Landsat 长时序遥感数据, 基于 CCDC 算法检测森林扰动以获得大量未标注扰动数据; 利用人工标注的少量样本数据和基于置信学习的互导框架, 以迭代方式从大量未标注扰动数据中筛选高置信度数据, 以扩充对方分类器的标注样本数量, 互相引导分类大量未标注扰动数据, 实现在小样本条件下的森林扰动类型分类.

1 研究区与数据

1.1 研究区

研究区位于靖州苗族侗族自治县和通道侗族自治县 ($25^{\circ}52'N-26^{\circ}47'N$, $109^{\circ}16'E-110^{\circ}01'E$), 隶属于湖南省怀化市南部 (见图 1). 靖州县和通道县的森林覆盖率约为 74.93% 和 77.24%^[36,37], 森林蓄积量为 0.013131 km^3 和 0.010679 km^3 ^[36,38], 主要为中亚热带湿润性常绿阔叶林^[39]. 研究区内主要森林扰动类型为




图 1 研究区地理位置 (1987 年 10 月 26 日的 Landsat5 真彩色图像)

Fig. 1 Geographic location of the study area (Natural color image of Landsat5 acquired on 26 October 1987)

林木砍伐、农田开垦、道路修建和火灾^[36].

1.2 数据和样本

1.2.1 土地覆盖参考数据

为了提取森林覆盖区域,获取森林稳定像元用于扰动检测精度评估以及减小 CCDC 检测的扰动数据中的错检,研究使用了土地覆盖参考数据 (China Land Cover Dataset, CLCD). 该数据空间分辨率为 30 m, 包含 1985 年、1999—2022 年的土地覆盖信息.

提取 1985 年 CLCD 数据中的林地区域作为森林掩膜. 1985 年的数据为研究提供了初始条件,帮助确定研究区在早期的森林覆盖状态. 这便于分析后续几十年中发生的变化. 此外,对 CLCD 数据计算逐年间差值,获取 CLCD 变化时间序列数据,然后提取 CCDC 检测的扰动数据与 CLCD 时序数据中相同变化部分以减小 CCDC 扰动检测中的错分误差,该数据用于后续扰动类型分类. 同时,随机选择 250 个稳定像元用于扰动检测精度评估.

1.2.2 Landsat 时间序列数据

为了获得研究区内的森林扰动数据,使用了 1986—2022 年的 Landsat5 TM, Landsat7 ETM+和 Landsat8 OLI/TIRS 时间序列数据. 这些影像均为 Collection2 L1 级,已完成几何配准. 使用陆地卫星生态系统扰动自适应处理系统 (LEDAPS)^[40,41] 进行大气校正,将原始亮度值 (Digital Number, DN) 转换为地表反射率. 为了在研究区气候条件下最大化可用数据覆盖,获取所有可用 Landsat 数据,筛选云量小于 80% 的 Landsat Collection2 Level-1 影像,研究期内可用影像共 1004 景. 数据云去除基于 Fmask 算法^[40].

研究区跨越两个 Landsat 路径 (PATH: 125, ROW 为 41/42). 为了保证时间序列数据的空间连续性,对相同日期的影像进行拼接,最终共有 357 景影像,具体见表 1. 数据基本满足 CCDC 算法要求.

1.2.3 样本数据获取

为了确定森林扰动类型和评估模型精度,基于年度火点数据集、砍伐记录、Google Earth Pro (GEP) 目视解译,构建森林扰动样本数据集. 结合湖南省林业局发布的森林资源调查数据,确定研究区的主要森林扰动类型为砍伐、火灾、开垦和道路建设,并将其作为本研究的分类类型 (见表 2). 年度火点数据来源于中国科学院遥感与数字地球研究所提供的年度地表高温异常点数据集,该数据集整合了 2013—2023 年的 Landsat8 高温点数据. 砍伐样本通过研究区内砍伐记录获取,包括皆伐和择伐. 同时,使用 GEP 上的高分辨率影像获取多类型样本.

为减少样本不平衡对分类精度的影响,解译的每类扰动样本数量设置为解译数量最少的开垦样本数量,即每类样本数量为 214,共解译 856 个样本. 根据 Olofsson 等^[42] 和 FCPF^[43] 的定义,每类样本数据量低于 323 时可定义为小样本. 研究按照 7:3 划分训练样本和测试样本.

2 森林扰动类型分类

2.1 森林扰动类型分类流程

研究使用的总体方法如图 2 所示. 首先,基于 1986—2022 年的 Landsat 时间序列数据,使用 CCDC

表 1 研究区所有可用 Landsat 数据的月统计
Table 1 All available Landsat data for the study area by month

月份	1月	2月	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月
影像数量	28	24	19	21	28	14	28	35	39	34	47	37

表 2 本文定义的森林扰动类型
Table 2 Type of forest disturbance defined in this paper

扰动类型	描述	来源	样本数量 (以像元为单位)
道路建设	在森林中修建道路及道路旁的服务设施	GEP	214
砍伐	在不转变为其他土地利用类型的情况下,砍伐造成的森林干扰	GEP和砍伐记录	214
开垦	在森林中开垦,用于农作物或经济林种植	GEP	214
火灾	火导致的森林燃烧,包括野火和人为火灾	GEP和Landsat8年度火点数据	214




图 2 基于置信学习互导框架的森林扰动类型分类流程

Fig. 2 Flowchart used to map forest disturbance drivers

算法获得大量未标注扰动数据, 并计算各种扰动事件的时、空、谱以及地形特征用于后续森林扰动类型分类. 利用人工标注的少量样本数据和基于随机森林 (Random Forest, RF) 和 梯度提升 (Categorical Boosting, CatBoost) 分类器构建的互导框架, 以迭代方式通过置信学习从大量未标注扰动数据中筛选高置信度数据, 以扩充对方分类器的样本数量, 互相指

导分类, 进而提升森林扰动类型分类精度.

2.2 基于 CCDC 算法森林扰动检测方法

研究基于 CCDC 时间序列分类算法进行森林扰动检测. 该算法利用所有可用的 Landsat 数据的 7 个波段检测土地覆盖/利用变化^[40]. 算法利用时间序列的前 15 个清晰像元观测值初始化模型, 然后对时间序列数据预测. 当像元观测值和模型预测值之间的差

异连续三次超过阈值时,则被认为该像元发生了变化.由于在2000年之前 Landsat 可用影像数量较少,但 CCDC 算法需要 15 个清晰观测以进行模型初始化,同时,时序末尾需要额外的观测以检测变化,导致 CCDC 算法在时间序列的开始和末尾年份易出现错分误差和漏分误差^[22,40].因此,这里只对 2000—2021 年进行扰动制图和分类.使用绿色、红色、近红外、短波红外 1、短波红外 2 波段以及 NBR 和 TC 指数进行森林扰动检测.为减少漏分误差,调整了确定为扰动的最小连续观测数量参数 minObservations 和卡方概率参数 chiSquareProbability.其中,minObservations 设置为 4,chiSquareProbability 设置为 0.9.

2.3 基于置信学习互导框架的森林扰动分类

2.3.1 特征选择

使用时间、空间、光谱以及地形特征进行扰动分类.将变化前光谱值(PreC_SI)、变化后光谱值(PostC_SI)以及变化幅度(MagC_SI-PreC_SI,

MagC_SI)作为时间特征(见图3).空间特征方面,基于 3×3~9×9 的滑动窗口计算了光谱均值(Mean_SI)和标准差(STD_SI)、基于 3×3 滑动窗口计算变化前后纹理特征的差异,包括相异性、对比度和方差.为了区分不同扰动类型,利用变化前后时间序列曲线的差异(两段曲线的截距变化幅度(Mag_INTP)和斜率变化幅度(Mag_SLP))作为光谱特征(见图3).另外,海拔与坡度等地形特征也被纳入分类特征.森林扰动分类特征如表3所示.

2.3.2 基于置信学习的互导框架分类算法

已有研究^[44,45]证明了 RF 和 CatBoost 能够基于少量样本保持较好的泛化性能,因此,这里采用 RF 和 CatBoost 作为互导框架中的两个基本分类器(见图4).同时,为了解决样本中的噪声问题以及避免类间数量不平衡问题,在互导框架中引入了置信学习^[46],并设置了样本增选数量规则,提高互导框架的泛化性能.




图3 时间和光谱特征概念

Fig. 3 Conceptual diagram of temporal feature and spectrum feature

表3 用于森林扰动类型分类的分类特征

Table 3 Categorical features for forest disturbance attribution

类型	特征(简称)	光谱指数 (Spectrum Index, SI)	描述
时间特征	变化前(PreC_SI)、变化后 (PostC_SI)、变化幅度(MagC_SI)	NBR, SWIR1, TCW, Tasseled TCG	变化前、变化后指数或波段光谱值以及变 化后与变化前的光谱差值
空间特征	滑动窗口内像元标准差(STD_SI)、 均值(Mean_SI) 相异性变化幅度(MagDiss_SI)、对比 度变化幅度(MagCon_SI)、方差变化幅 度(MagVar_SI)	NBR, SWIR1, TCW, TCG NBR, SWIR1, TCG	3×3, 5×5, 7×7, 9×9滑动窗口内指数或波 段光谱值的标准差、均值 3×3 滑动窗口内变化后与变化前纹理特征 (相异性、对比度、方差)的差值
光谱特征	拟合“片段”的截距变化幅度 (Mag_INTP)、斜率变化幅度 (Mag_SLP)	截距(INTP)、斜率 (SLP)	CCDC拟合的变化后与变化前片段的趋势 线的截距或斜率差值
地形特征	海拔、坡度	数字高程模型(Digital Elevation Model, DEM)	高程、坡度




图 4 基于 RF 和 CatBoost 分类器构建的置信学习互导框架

Fig. 4 Schematic diagram of the confidence learning mutual guidance framework constructed based on RF and CatBoost classifiers

2.3.2.1 置信学习选择样本

置信学习可直接估计噪声标签与真实标签的分布, 将置信学习应用于多分类器互导框架, 可自动识别基分类器错误标注的样本并过滤. 研究将分类器错误标注的标签作为噪声标签, 通过交叉验证估计得到的标签作为真实标签. 为尽可能保证标签的正确性, 过滤基于噪声和真实标签的联合分布中的错误样本, 错误样本包括置信度很高, 但实际给定的标签与预测标签不匹配的样本, 以及各类中置信度最低的样本.

使用训练样本集对分类器训练, 训练好的分类器对待分类像元数据 X_C 分类. 为确保输入到置信学习中的数据中的可靠性以及减小交叉验证所需要的时间, 采用类别概率值初次筛选

$$X_{M,H} = S_M(P, X_C), P > T_P; \quad (1)$$

$$Y_{M,H} = S_M(P, Y), P > T_P. \quad (2)$$

其中, P 为类别概率集, Y 为预测标签集, $S_M(\cdot)$ 为排序选择函数, T_P 为概率阈值. 通过对类别概率排序, 从分类像元数据 X_C 和预测标签数据 Y 中选择 M 个概率最大的待分类数据和预测标签.

为避免类别数量不平衡导致分类器学习偏差, 采用类别数量最小值作为数据量选择基数, 即

$$N_{\min} = \text{Min}[\text{sum}(Y_{M,H} == p), p \in P], \quad (3)$$

$$M = P \times N_{\min}. \quad (4)$$

按照最小值分别为每个类别选择前 $N_{\min}$ 个待分类像元数据和预测标签数据. 若筛选的数据总数 M 小于 100, 导致获取的样本外预测概率存在较大误差.

因此, 降低类别概率阈值 T_P . 反之, 选出 M 个高类别概率的待分类像元数据 $X_{M,H}$ 和预测标签数据 $Y_{M,H}$.

但选出的数据中存在噪声, 影响模型的分类, 因此引入置信学习, 找出高类别概率中的待分类像元数据 $X_{M,H}$ 和预测标签数据 $Y_{M,H}$ 中标注错误的样本并筛选

$$X_C, Y_C = F(Y_{M,H}, P_{M,\text{OOS}}). \quad (5)$$

其中, $F(\cdot)$ 为置信学习^[46], X_C 为正确标注数据, Y_C 为对应预测标签数据, $P_{M,\text{OOS}}$ 为对应样本外的预测概率, 通过交叉验证计算得到.

为了保证标签质量高和类别数量平衡, 计算标签质量分数 Q , 根据标签质量分数设置质量阈值 T_Q , 可以得到如下最终引导数据 $X_{N,G}$ 和引导标签 $Y_{N,G}$:

$$X_{N,G} = S_N(Q, X_C), Q \geq T_Q; \quad (6)$$

$$Y_{N,G} = S_N(Q, Y_C), Q \geq T_Q. \quad (7)$$

其中, N 表示引导数据的数量, 若 N 值为 0, 降低质量分数阈值 T_Q . 通过实验发现, 迭代过程中, 筛选的 N 过大, 会造成分类器泛化能力快速下降. 因此设置筛选数量规则: 若 $N \leq 20$, 则不变; 反之, $N = 20$.

2.3.2.2 互导框架互导分类

互导框架 (见图 4) 采用 RF 和 CatBoost 两个分类器以迭代的方式增选样本. 每次迭代包括三个部分: 训练^[47]、分类^[47]、样本增选.

(1) 第 k 次训练. 在第 k 次训练中, 每个分类器的训练数据由初始训练数据和对方分类器在前 $k-1$ 次迭代中选出的引导标签组成.

(2) 第 k 次分类. 训练完成后, 分类器对待分类数据进行预测, 得到新的预测标签和分类器分类精度 (总体精度 OA).

(3) 第 k 次样本增选. 通过置信学习剔除错误标注数据, 同时计算类别概率和质量分数以平衡类别数量, 实现第 k 次样本增选. 选出的引导标签被加入对方训练数据集中, 同时未标注样本集中相应数据被移除, 并进入下一次迭代. 特别地, 若第 k 次分类中分类器精度小于或等于第 $k-1$ 次, 则降低筛选高类别概率的阈值, 增加进行置信学习的待分类数据和预测标签数据的数据量, 重新选择引导数据和引导标签, 直到第 k 次分类精度高于第 $k-1$ 次.

(4) 迭代停止与最终分类结果. 当分类器第 k 次分类精度均达到阈值, 且相较第 $k-1$ 次分类精度无明显变化则停止迭代. 若互导后两分类器的所得标签一致, 则分类结果为一一致标签; 若标签不一致, 则选取质量分数更高的标签为最终分类结果.

2.3.2.3 模型评估

为了便于检测迭代过程中模型性能的变化, 将测试样本集纳入待分类数据集. 基于测试样本集, 在扰动检测和类型分类中, 均采用混淆矩阵评估算法的准确性. 以总体精度 (Overall Accuracy, OA) 来评估整体的准确性, 生产者精度 (Producer Accuracy, PA)

和使用者精度 (User Accuracy, UA) 评估每一类的分类情况.

3 结果与分析

3.1 森林扰动检测精度评估

为了评估 CCDC 扰动检测的精度, 从 CLCD 数据随机选择了 250 个稳定样本, 从检测结果中随机选择了 250 个扰动样本, 评估结果见表 4.

为减小错分误差, 缩减制图时间范围至 2000—2021 年, 并取 CLCD 数据和 CCDC 扰动检测结果数据的并集. 最终, 森林扰动检测的总体精度为 92.8% (见表 5), 相较 CCDC 的扰动检测结果, 稳定像元的用户精度提高了 0.2%, 扰动像元和稳定像元的生产者精度分别提高了 4.2%, 0.3%.

从扰动检测结果中随机选择 233 个正确分类的扰动像元, 通过比较算法检测与参考数据记录的扰动时间的一致性以评估时间精度. 时间精度评估结果如表 6 所示, 整体时间精度为 79.4%, 超过 80% 的像元在 2 个时间步长延迟内 (约 32 天) 被检测到, 表明该算法具有较高的时间精度.

3.2 基于置信学习互导框架的分类性能

基于置信学习的互导框架以迭代方式向对方分

表 4 CCDC 扰动检测的空间域精度评估

Table 4 Accuracy assessment of disturbance detection in the spatial domain with different parameters

	扰动像元(真实)	稳定像元(真实)	总数	用户精度/(%)
扰动像元(预测)	233	17	250	93.2
稳定像元(预测)	31	219	250	87.6
总数	264	236	500	—
生产者精度/(%)	88.3	92.8	—	—
总体精度/(%)	90.4			

表 5 经过后处理的扰动检测空间域精度评估

Table 5 Post-processing accuracy assessment of disturbance detection in the spatial domain

	扰动像元(真实)	稳定像元(真实)	总数	用户精度/(%)
扰动像元(预测)	233	17	250	93.2
稳定像元(预测)	19	231	250	90.2
总数	252	248	500	—
生产者精度/(%)	92.5	93.1	—	—
总体精度/(%)	92.8			

类器提供高置信度样本, 以实现互相指导. 在本研究中, RF 和 CatBoost 分类器在迭代中逐步增加样本量以提高分类精度. 在迭代过程中, 两个分类器的训练样本数量的增加和总体精度的提升如图 5(a)(b) 所示. 在图 5 中, 当互导次数为 0 时 (未增选样本, 使用初始训练样本), 数据量为 599; 其中 RF 分类的总体精度为 84.8%, 而 CatBoost 为 86.4%.

在图 5(a) 中, RF 和 CatBoost 分类器在迭代过程中每次增选的样本数据量不同, 但迭代开始时增选的样本量均比迭代后期少, 这表明随着迭代次数的增加, 增选样本的置信度不断提高. 同时, 分类器的总体精度均随着互导次数的增加而增加 (见图 5b). 虽然两个分类器总体精度的增加幅度不同, 但最后均达到了 90% 以上, 最终模型的整体精度为 91.4%, 与只利用初始训练样本分类精度相比, 互导框架将总体精度提升了 5% (86.4%~91.4%). 增选样本置信度的提高和分类精度的提升均表明互导框架在迭代训练中, 随着互导次数的增加, 能够不断筛选出更多的有效样本, 迭代优化分类器的性能, 进而提升了模型的泛化能力.

3.3 不同样本量下互导框架分类性能评价

为评估小样本条件下互导框架的分类性能, 研究

比较了不同初始训练样本数量下的互导框架分类精度. 以 100 为步长, 将初始训练样本数据量从 100 逐步增加到 500. 为保证不同训练样本数据量下分类精度的可比性, 设定测试样本数据量统一为初始测试样本数量 257, 结果如图 6 和图 7 所示. 在图 6 和图 7 中在不同样本量下, 互导框架在每次迭代中通过置信学习筛选的样本量不同, 导致互导框架的收敛速度有所差异. 以分类的总体精度变化趋于稳定作为收敛的判断标准, 因此不同样本量下迭代次数有所不同. 为避免统一迭代次数, 可能会导致某些样本量下的分类性能未能充分展现或过度迭代引入噪声问题, 选择不同的迭代次数准确反映互导框架在不同样本量下的真实性能.

在相同初始样本量下, 互导框架在总体精度方面优于只利用初始样本分类的单一分类器 (见图 8). 互导框架以迭代方式通过置信学习筛选高置信度样本 (见图 6 和图 7), 每次迭代两个分类器选择的高置信度样本数量不同, 利用框架更充分地学习样本. 在初始训练样本量为 100 时, 只利用初始训练样本分类的总体精度为 70.0%, 互导框架通过 5 次迭代, 将样本数量从 100 扩充到 156, 从而将总体精度提升到

表 6 经过后处理的扰动检测时间域精度评估

Table 6 Post-processing accuracy assessment of disturbance detection in the temporal domain

	相同时间	延迟 ≤ 2 个时间步长	延迟 > 2 个时间步长	总数
扰动像元	185	5	43	233
比例/(%)	79.4	2.1	18.5	100.0




图 5 迭代过程中指标的变化. (a) 训练样本数量的变化, (b) 总体精度的变化

Fig. 5 Changes in metrics during iteration. (a) Changes in sample size, (b) changes in overall accuracy




图6 RF和CatBoost分类器的样本数量及总体精度变化(初始训练样本量: 100, 200, 300)
Fig. 6 Variation in the number of samples, overall accuracy of RF and CatBoost classifiers
(Initial training samples: 100, 200, 300)

72.8%, 精度提升幅度为 3.5%。这表明, 互导框架在有限样本量情况下具有显著的精度提升效果, 能够更有效地利用已有的样本信息, 弥补初始样本量不足带来的准确性缺陷。

随着初始训练样本量的增加, 训练样本增选数量和分类器的总体精度提升均变得更加明显。由图 8 可看出, 初始样本量越大, 互导框架的分类精度越高, 从初始样本量为 100 的 72.8% 提升到初始样本量为 500 的 90.3%。当初始样本量为 100 时, 互导框架增选样本数量为 56, 精度提升了 2.7%。当初始样本量为

500 时, 互导框架增选样本数量为 85, 提升精度为 2.3% (见图 6 和图 7)。互导框架提高分类精度受初始样本量的影响较大。初始样本量越大, 模型分类的总体精度提升越缓慢, 但能达到较好的分类精度。可以看出, 所研究的互导框架在不同数量的训练样本中都表现较好, 这表明此互导框架对于训练样本数据较少的森林扰动类型分类具有有效性。

3.4 森林扰动类型分类精度评估与制图

这里将互导框架提升的最终精度作为森林扰动类型分类的准确性评估结果 (见表 7)。评估整体分类




图 7 RF 和 CatBoost 分类器的样本数量及总体精度变化 (初始训练样本量: 400, 500)

Fig. 7 Variation in the number of samples, overall accuracy of RF and CatBoost classifiers (Initial training samples: 400, 500)




图 8 不同初始训练样本量下单一分类器与互导框架分类性能变化

Fig. 8 Changes in classification performance of single classifier and mutual guidance framework with different initial training sample sizes

情况以及 4 类森林扰动类型 (道路建设、砍伐、开垦和火灾) 分类的用户精度和生产者精度. 在研究中基于置信学习互导框架的总体分类精度达到了 91.4%. 道路建设、开垦以及火灾的生产者精度均大于 90%,

砍伐的生产者精度较低 (88.3%).

砍伐类型的用户精度 (错检) 和生产者精度 (漏检) 均较低 (较高), 其主要原因为: 砍伐的空间特征与开垦具有相似性, 导致砍伐被错检为开垦, 同时砍伐后裸露的草地与开垦后生长的草地具有空间和光谱相似性, 也导致砍伐被错检 (见图 9); 砍伐往往在道路周边缓冲区范围内进行, 30 m 空间分辨率的单个像元为道路和砍伐的混合像元, 砍伐引起的光谱变化幅度低, 导致被漏检.

2000—2021 年的年度扰动类型空间分布如图 10(a) 所示. 砍伐和火灾是研究区的主要扰动类型, 分布于整个研究区, 而开垦活动集中发生在森林边缘区域. 道路建设事件主要分布在研究区和森林的边缘地区, 且几乎贯穿整个研究区. 由于缺乏分类验证数据, 采用 Landsat 影像对分类结果进行了验证. 具体而言, 通过对比基于置信学习互导框架得到的扰动类型分类结果与影像实际变化来评估分类的准确性. 图 11 给出了分类结果与实际影像变化的对比, 可以看出分类结果与实际变化较为一致. 此外, 本文采用 MODIS 火灾数据 (MCD64 A1) 来进一步验证火灾

表 7 基于置信学习互导框架的森林扰动类型分类混淆矩阵
Table 7 Confusion matrix for forest disturbance attribution based on confidence learning mutual guidance framework

	道路建设(预测)	砍伐(预测)	开垦(预测)	火灾(预测)	用户精度/(%)
道路建设(真实)	57	5	0	1	90.4
砍伐(真实)	2	53	3	1	88.3
开垦(真实)	4	1	61	2	92.4
火灾(真实)	0	1	2	64	94.1
生产者精度/(%)	90.5	89.8	89.7	94.1	—
总体精度/(%)			91.4		




图 9 基于置信学习互导框架在森林扰动类型分类的错分. (a) (i) 均来源于 GEP, (b) (j) 为扰动分类, (c)~(h) 为森林砍伐的 Landsat 时间序列, 真彩色显示 (波段 321 组合), (k)~(p) 为开垦

Fig. 9 Misclassification of forest disturbance attribution based on the confidence learning mutual guidance framework. (a) and (i) are from GEP, (b) and (j) are disturbance classification maps, (c)~(h) are Landsat time series of deforestation, shown in true color (band 321 combinations), and (k)~(p) are reclamation

分类结果. 由于 MODIS 火灾数据的空间分辨率较低 (1 km), 统计了 MODIS 火灾点上本研究是否检测出火灾. 结果显示, 90.71% 的 MODIS 火灾点被本文的分类方法所识别. 这表明本文的分类结果在火灾检测方面具有较高的准确性.

森林扰动主要发生在 2013 年以前, 2014 年之后较少; 从整体上来看, 森林扰动事件的发生呈现减少趋势 (见图 10b 和图 12). 研究期内, 森林受到不同扰动类型影响的面积达 1392.3 km², 每年造成的森林损失如图 12 所示. 其中 2012 年由于仅有两景可用影




图 10 森林扰动. (a) 扰动类型, (b) 扰动年度

Fig. 10 Forest disturbance maps. (a) Disturbance by causal agents, (b) the disturbance map at an annual step




图 11 基于置信学习互导框架的扰动类型分类. (a) 2010 年 Landsat8 影像真彩色合成——道路建设, (b) 2010 年分类结果——道路建设, (c) 2013 年 Landsat8 影像真彩色合成——砍伐, (d) 2013 年分类结果——砍伐, (e) 2009 年 Landsat8 影像真彩色合成——火灾, (f) 2013 年分类结果——火灾, (g) 2009 年 Landsat8 影像真彩色合成——开垦, (h) 2013 年分类结果——开垦

Fig. 11 Classification of disturbance types based on the confidence learning mutual conductivity framework. (a) 2010 Landsat8 imagery true color synthesis – roads construction, (b) 2010 classification results – roads construction, (c) 2013 Landsat8 imagery true color composite – logging, (d) 2013 classification results – logging, (e) 2009 Landsat8 imagery true color composite – fire, (f) 2013 classification results – fire, (g) 2009 Landsat8 image true color composite – clearing, (h) 2013 classification results – clearing

像, 检测到的扰动面积小.

4 结论

森林生态系统作为地球陆表系统的重要组成部

分, 了解其扰动过程和驱动力有助于更好地理解地球系统复杂变化过程. 而建立在空间科学基础上的遥感技术因其时空连续性观测特点, 在开展森林生态系统扰动类型分类及其时空分布分析方面具有精准和高效的优势. 为解决基于遥感技术的森林扰动类型分类




图 12 2000—2021 年不同扰动类型导致的森林损失面积统计

Fig. 12 Statistics on the area of forest loss due to different disturbance types from 2000 to 2021

样本量少的现实问题, 本文构建了一个基于置信学习的互导框架, 用于小样本条件下的森林扰动类型分类. 使用 CCDC 算法检测了森林扰动, 其检测的精度为 92.8%, 为后续森林扰动类型分类提供扰动数据. 提取了时间、空间、光谱和地形四个方面的特征, 用于区分不同扰动类型. 利用基于置信学习的互导框架进行扰动分类. 互导框架通过置信学习识别并过滤噪声样本, 结合 RF 和 CatBoost 分类器的相互引导进行样本增选, 有效解决了小样本问题, 显著提高了森林扰动类型的分类精度. 基于置信学习的互导框架在小样本条件下对森林扰动类型的分类精度为 91.4%, 表现出优异的性能, 相比使用单个分类器, 最终分类精度提升 5%. 研究表明, 森林扰动面积在研究期间呈现减少趋势. 森林扰动事件主要发生在 2013 年以前, 2014 年之后较少. 在研究期内, 森林面积损失了 1392.3 km^2 . 此外, 砍伐和火灾是研究区的主要扰动类型. 对靖州苗族侗族自治县和通道侗族自治县森林扰动及其扰动类型的识别不仅可以揭示研究区内不同扰动类型导致的森林损失情况, 还可为该区的碳汇估算、森林资源管理和保护提供参考.

尽管本文构建的互导框架取得了较好的分类效果, 但提取的空间特征不能很好地区分砍伐与其他扰动类型, 导致砍伐的分类精度低, 需要在未来研究中着重提高模型在区分砍伐与其他类型的能力. 此外, 研究可以考虑更为灵活的样本筛选机制, 以适应不同初始扰动样本量下的森林扰动类型分类. 例如, 在初始样本量较少时 (少于 300), 设置较高的置信度阈值, 使得互导框架能够更稳健地提高分类精度幅度. 另

外, 可探索引入更多的分类器组成多分类器体系, 以进一步增强框架的稳定性和适应性.

参考文献

- [1] SHI Jiancheng, ZHAO Tianjie, YANG Xiaofeng. Global water cycle studies from the perspective of space earth science[J]. *National Remote Sensing Bulletin*, 2021, **25**(4): 847-855 (施建成, 赵天杰, 杨晓峰. 空间地球科学视角下的全球水循环研究 [J]. *遥感学报*, 2021, **25**(4): 847-855)
- [2] TIAN Zhenpeng, ZHOU Wei, YUAN Jingyi, *et al.* Forest canopy height mapping based on multi-source remote sensing data[J]. *Chinese Journal of Space Science*, 2023, **43**(6): 1176-1193 (田镇朋, 周维, 袁敬毅, 等. 基于多源遥感数据的植被冠层高度估算 [J]. *空间科学学报*, 2023, **43**(6): 1176-1193)
- [3] XU R, LI Y, TEULING A J, *et al.* Contrasting impacts of forests on cloud cover based on satellite observations[J]. *Nature Communications*, 2022, **13**(1): 670
- [4] FEDERICI S, TUBIELLO F N, SALVATORE M, *et al.* New estimates of CO_2 forest emissions and removals: 1990-2015[J]. *Forest Ecology and Management*, 2015, **352**: 89-98
- [5] MACDICKEN K G. Global forest resources assessment 2015: What, why and how?[J]. *Forest Ecology and Management*, 2015, **352**: 3-8
- [6] STAHL A T, ANDRUS R, HICKE J A, *et al.* Automated attribution of forest disturbance types from remote sensing data: a synthesis[J]. *Remote Sensing of Environment*, 2023, **285**: 113416
- [7] SENF C, SEIDL R. Mapping the forest disturbance regimes of Europe[J]. *Nature Sustainability*, 2021, **4**(1): 63-70
- [8] MCDOWELL N G, ALLEN C D, ANDERSON-TEIXEIRA K, *et al.* Pervasive shifts in forest dynamics in a changing world[J]. *Science*, 2020, **368**(6494): 964
- [9] OESER J, PFLUGMACHER D, SENF C, *et al.* Using in-

- tra-annual Landsat time series for attributing forest disturbance agents in Central Europe[J]. *Forests*, 2017, **8**(7): 251
- [10] SEBALD J, SENF C, SEIDL R. Human or Natural? Landscape context improves the attribution of forest disturbances mapped from Landsat in central Europe[J]. *Remote Sensing of Environment*, 2021, **262**: 112502
- [11] PICKETT S T A, WHITE P S. The Ecology of Natural Disturbance and Patch Dynamics[M]. New York: Academic Press, 1985
- [12] BONAN G B. Forests and climate change: forcings, feedbacks, and the climate benefits of forests[J]. *Science*, 2008, **320**(5882): 1444-1449
- [13] GOLDSTEIN G, SANTIAGO L S. Tropical Tree Physiology: Adaptations and Responses in A Changing Environment[M]. Cham: Springer, 2016: 337-355
- [14] MASCORRO V S, COOPS N C, KURZ W A, *et al.* Choice of satellite imagery and attribution of changes to disturbance type strongly affects forest carbon balance estimates[J]. *Carbon Balance and Management*, 2015, **10**(1): 30
- [15] LEHNERT L W, BÄSSLER C, BRANDL R, *et al.* Conservation value of forests attacked by bark beetles: highest number of indicator species is found in early successional stages[J]. *Journal for Nature Conservation*, 2013, **21**(2): 97-104
- [16] SEIDL R, RAMMER W, JÄGER D, *et al.* Impact of bark beetle (*Ips typographus* L.) disturbance on timber production and carbon sequestration in different management strategies under climate change[J]. *Forest Ecology and Management*, 2008, **256**(3): 209-220
- [17] DE SY V, HEROLD M, ACHARD F, *et al.* Land use patterns and related carbon losses following deforestation in South America[J]. *Environmental Research Letters*, 2015, **10**(12): 124004
- [18] CURTIS P G, SLAY C M, HARRIS N L, *et al.* Classifying drivers of global forest loss[J]. *Science*, 2018, **361**(6407): 1108-1111
- [19] CHEN X, ZHAO W Z, CHEN J G, *et al.* Mapping large-scale forest disturbance types with multi-temporal CNN framework[J]. *Remote Sensing*, 2021, **13**(24): 5177
- [20] LI Y T, XU X, WU Z Z, *et al.* A forest type-specific threshold method for improving forest disturbance and agent attribution mapping[J]. *GIScience & Remote Sensing*, 2022, **59**(1): 1624-1642
- [21] DE MARZO T, GASPARRI N I, LAMBIN E F, *et al.* Agents of forest disturbance in the argentine dry Chaco[J]. *Remote Sensing*, 2022, **14**(7): 1758
- [22] ZHANG Y T, WOODCOCK C E, CHEN S J, *et al.* Mapping causal agents of disturbance in boreal and arctic ecosystems of North America using time series of Landsat data[J]. *Remote Sensing of Environment*, 2022, **272**: 112935
- [23] SHIMIZU K, OTA T, MIZOUE N, *et al.* A comprehensive evaluation of disturbance agent classification approaches: strengths of ensemble classification, multiple indices, Spatio-temporal variables, and direct prediction[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, **158**: 99-112
- [24] WU Ling, LIU Xiangnan, LIU Meiling, *et al.* Review of the detection and attribution of multi-type forest disturbances using an ensemble of Spatio-temporal-spectral information from remote sensing images[J]. *National Remote Sensing Bulletin*, 2024, **28**(3): 558-575 (吴伶, 刘湘南, 刘美玲, 等. 融合遥感时间序列时空谱信息的森林扰动检测与归因研究进展[J]. 遥感学报, 2024, **28**(3): 558-575)
- [25] XIAO P F, SHENG G W, ZHANG X L, *et al.* Direction-dominated change vector analysis for forest change detection[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, **103**: 102492
- [26] FRANKLIN S, ROBITAILLE S. Forest insect defoliation and mortality classification using annual Landsat time series composites: a case study in Northwestern Ontario, Canada[J]. *Remote Sensing Letters*, 2020, **11**(12): 1175-1180
- [27] LI Y T, WU Z Z, XU X, *et al.* Forest disturbances and the attribution derived from yearly Landsat time series over 1990-2020 in the Hengduan mountains region of Southwest China[J]. *Forest Ecosystems*, 2021, **8**(1): 73
- [28] VOGELER J C, SLESACK R A, FEKETTY P A, *et al.* Characterizing over four decades of forest disturbance in Minnesota, USA[J]. *Forests*, 2020, **11**(3): 362
- [29] MURILLO-SANDOVAL P J, HILKER T, KRAWCHUK M A, *et al.* Detecting and attributing drivers of forest disturbance in the Colombian Andes using Landsat Time-Series[J]. *Forests*, 2018, **9**(5): 269
- [30] DAS P, MUDI S, BEHERA M D, *et al.* Automated mapping for long-term analysis of shifting cultivation in Northeast India[J]. *Remote Sensing*, 2021, **13**(6): 1066
- [31] GAO B C. NDWI-a normalized difference water index for remote sensing of vegetation liquid water from Space[J]. *Remote Sensing of Environment*, 1996, **58**(3): 257-266
- [32] CHEN S J, OLOFSSON P, SAPHANGTHONG T, *et al.* Monitoring shifting cultivation in Laos with Landsat Time series[J]. *Remote Sensing of Environment*, 2023, **288**: 113507
- [33] CARDILLE J A, PEREZ E, CROWLEY M A, *et al.* Multi-sensor change detection for within-year capture and labelling of forest disturbance[J]. *Remote Sensing of Environment*, 2022, **268**: 112741
- [34] FRAZIER R J, COOPS N C, WULDER M A. Boreal shield forest disturbance and recovery trends using Landsat time series[J]. *Remote Sensing of Environment*, 2015, **170**: 317-327
- [35] SENF C, PFLUGMACHER D, HOSTERT P, *et al.* Using Landsat time series for characterizing forest disturbance dynamics in the coupled human and natural systems of

- Central Europe[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, **130**: 453-463
- [36] GAO Junye. Dynamic Change of Forest Types Based on Multi-Source Remote Sensing Data[D]. Changsha: Central South University of Forestry & Technology, 2021 (高珺烨. 基于多源遥感数据的森林类型动态变化研究[D]. 长沙: 中南林业科技大学, 2021)
- [37] ZHANG T W, WU L, LIU X N, *et al.* Detection of forest disturbances with different intensities using Landsat time series based on adaptive exponentially weighted moving average charts[J]. *Forests*, 2023, **15**(1): 19
- [38] WANG Kaixin, XIA Xin. Analysis on forest resource characteristics in Tongdao County based on GIS technology[J]. *South China Agriculture*, 2024, **18**(13): 258-261 (王开新, 夏昕. 基于 GIS 技术的通道县森林资源特征分析[J]. 南方农业, 2024, **18**(13): 258-261)
- [39] WU Zibin, LONG Dingxiu, LU Zhiwang, *et al.* Investigation on habitation village ecosystems dominated by dong people in Tongdao County, Hu'nan province[J]. *Journal of Green Science and Technology*, 2016(6): 70-73,75 (吴子斌, 龙丁秀, 陆志旺, 等. 湖南省通道县侗族聚居村寨环境生态系统调查[J]. 绿色科技, 2016(6): 70-73,75)
- [40] ZHU Z, WOODCOCK C E. Continuous change detection and classification of land cover using all available Landsat Data[J]. *Remote Sensing of Environment*, 2014, **144**: 152-171
- [41] MASEK J G, VERMOTE E F, SALEOUS N E, *et al.* A Landsat surface reflectance data set for North America, 1990-2000[J]. *Geoscience and Remote Sensing Letters*, 2006, **3**(1): 68-72
- [42] OLOFSSON P, FOODY G M, HEROLD M, *et al.* Good practices for estimating area and assessing accuracy of land change[J]. *Remote Sensing of Environment*, 2014, **148**: 42-57
- [43] FCPF. Guidelines on the application of the Methodological framework Number 2-On Technical Corrections to GHG emissions and removals reported in the reference period [EB/OL]. (2020-11-01)[2024-10-29]. https://www.forestcarbonpartnership.org/sites/fcp/files/FCPF%20Guidelines%20on%20the%20Application%20of%20the%20Methodological%20Framework%20Number%202_2020_0.pdf
- [44] CAVALHEIRO L P, BERNARD S, BARDDAL J P, *et al.* Random forest kernel for high-dimension low sample size classification[J]. *Statistics and Computing*, 2024, **34**(1): 9
- [45] DONG J X, YU Z S, ZHANG X K, *et al.* Data-driven predictive prognostic model for power batteries based on machine learning[J]. *Process Safety and Environmental Protection*, 2023, **172**: 894-907
- [46] NORTH CUTT C G, JIANG L, CHUANG I. Confident learning: estimating uncertainty in dataset labels[J]. *Journal of Artificial Intelligence Research*, 2021, **70**: 1373-1411
- [47] TAI X X, LI M J, XIANG M, *et al.* A mutual guide framework for training hyperspectral image classifiers with small data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, **60**: 5510417

作者简介



严 燕 女, 1998 年 10 月出生, 现为中国地质大学硕士研究生, 主要研究方向为机器学习、时空数据挖掘与森林扰动分类。
E-mail: 2004220026@email.cugb.edu.cn



叶 昕 (通信作者) 男, 1992 年 5 月出生, 现为中国农业大学信息与电气工程学院副教授, 硕士生导师, 主要研究方向为热红外遥感与深度学习。
E-mail: yexin@cau.edu.cn