https://doi.org/10.3799/dqkx.2025.296

深度网络耦合遥感的重大铁路工程施工期生态环境质量评价

姬翠翠[1,2,3,4],万 胜[1],黄早阳[1],张晓超[2,3,5],罗 璟[3,5],杨恒聪[1*],裴向军[2,3,4,5*]

1. 重庆交通大学智慧城市学院,重庆 400074
2. 成都理工大学生态环境学院,四川成都 610059
3. 成都理工大学地质灾害防治与地质环境保护全国重点实验室,四川成都 610059
4. 成都理工大学国家环境保护水土污染协同控制与联合修复重点实验室,四川成都 610059
5. 天府永兴实验室,四川成都 610213

摘 要: 针对西南山区重大铁路工程施工期生态环境扰动监测空间精度低的问题,本研究提出运用"深度网络耦合遥感光谱特征"框架进行生态环境质量动态评价.利用2019—2024年Sentinel-2的10 m分辨率时序影像,构建由影像光谱波段、光谱指数和纹理特征组成的输入特征集,采用U-Net语义分割模型,动态评价多年西南山区重大铁路工程施工期生态环境质量,并与全卷积网络(FCN)和LinkNet模型评价成效进行对比.结果表明:U-Net测试集精度达91.65%,显著优于FCN(82.95%)和LinkNet(90.23%),该网络模型结合光谱波段和植被指数特征更鲁棒可靠.其次,发现2019—2024年优等区面积锐减28.5%,精准识别出2021—2022年铁路主体施工期为生态退化关键阶段,生态质量指数下降0.18.再者,结合变化分析揭示了"一般→较差"与"良→一般"为主的生态退化路径,并量化了扰动时空异质性,发现以弃渣场、交通便道为主体的持续退化热点区域.总体区域上生态质量呈"东西高、中间低"格局,优等区分布在林地为主区域,差等区集中在稀疏灌草的生态退化区域.研究证明,深度学习网络耦合遥感光谱特征方法可成为铁路工程施工期生态环境质量评价的新范式,能够实现复杂山区交通廊道生态质量的高精度、快速监测,为重大铁路工程生态风险精准防控与恢复策略制定提供科学依据.

关键词: 重大铁路工程;生态环境评价;深度学习网络;光谱特征;遥感;机器学习.

中图分类号: P642.5 **文章编号:** 1000—2383(2026)09—3405—17 **收稿日期:** 2025—09—01

Eco-Environmental Quality Assessment of Major Railway Project Construction Period by Deep Learning Network Coupled with Remote Sensing

Ji Cuicui[1,2,3,4], Wan Sheng[1], Huang Zaoyang[1], Zhang Xiaochao[2,3,5], Luo Jing[3,5], Yang Hengcong[1*], Pei Xiangjun[2,3,4,5*]

1. *School of Smart City, Chongqing Jiaotong University, Chongqing* 400074, *China*
2. *College of Ecology and Environment, Chengdu University of Technology, Chengdu* 610059, *China*
3. *State Key Laboratory of Geohazard Prevention and Geoenvironment Protection, Chengdu University of Technology,*

基金项目: 国家重点研发计划项目(No. 2023YFC3007103);西藏自治区重点研发项目(No. XZ202401ZY0091);天府永兴重大项目(No. 2023KJGG05);国家自然科学青年基金项目(No. 42301459);地质灾害防治与地质环境保护国家重点实验室开放基金资助项目(No. SKLGP2022K028);国家环境保护水土污染协同控制与联合修复重点实验室开放基金项目(No. GHBK-2023-04).

作者简介: 姬翠翠(1984—),女,副教授,博士生导师,研究方向为植被参量定量反演、森林火灾风险评估和区域生态环境遥感监测.ORCID:0000-0001-7764-6422. E-mail:cuicuiji@whu.edu.cn

* **通讯作者:** 杨恒聪,E-mail:yanghc@mails.cqjtu.edu.cn;裴向军,E-mail:pxj@cdut.edu.cn

引用格式: 姬翠翠,万胜,黄早阳,张晓超,罗璟,杨恒聪,裴向军,2026.深度网络耦合遥感的重大铁路工程施工期生态环境质量评价.地球科学,51(9):3405—3421.

Citation: Ji Cuicui, Wan Sheng, Huang Zaoyang, Zhang Xiaochao, Luo Jing, Yang Hengcong, Pei Xiangjun, 2026. Eco-Environmental Quality Assessment of Major Railway Project Construction Period by Deep Learning Network Coupled with Remote Sensing. *Earth Science*, 51(9):3405—3421.

Chengdu 610059, *China*
4. *State Environmental Protection Key Laboratory of Synergetic Control and Joint Remediation for Soil & Water Pollution*, *Chengdu University of Technology*, *Chengdu* 610059, *China*
5. *Tianfu Yongxing Laboratory*, *Chengdu* 610213, *China*

Abstract: To address the challenges of low spatial accuracy and poor spatio-temporal continuity in monitoring ecological disturbances in the construction of major railway projects in mountainous regions of Southwest China, this study proposes a dynamic evaluation framework that integrates deep networks with remote sensing spectral features. Using Sentinel-2 10 m resolution time-series imagery from 2019 to 2024, we developed input feature datasets comprising bands of remote sensing images, spectral indices and textural features. A U-Net-based semantic segmentation model was developed for assessing ecological quality, with comparative analyses conducted against FCN and LinkNet. This approach enabled dynamic evaluation of ecological quality during the construction period of the railway in the mountainous areas of Southwest China in years. The results show that the U-Net model achieved a test accuracy of 91.65%, significantly outperforming FCN (82.95%) and LinkNet (90.23%), demonstrating its robustness when coupled with spectral features. From 2019 to 2024, the area of high-quality zones decreased sharply by 28.5%, with the main construction period of 2021-2022 identified as the most critical phase of ecological degradation, during which the ecological quality index dropped by 0.18. Change trajectory analysis further revealed dominant degradation pathways, such as "moderate→poor" and "good→moderate", and quantified the spatio-temporal heterogeneity of disturbances. Persistent degradation hotspots were primarily associated with waste dump sites and construction access roads. Overall, the region exhibited a spatial pattern of "high quality in the east and west, low in the center" in which high-quality zones are distributed in areas dominated by forest land, while the low-quality zones are concentrated in ecologically degraded areas with sparse shrubs and grasses. This study demonstrates that integrating deep learning with remote sensing spectral features provides a novel paradigm for ecological quality assessment during railway construction. It enables rapid high-precision monitoring of ecological quality in complex mountainous corridors, offering a scientific basis for precise ecological risk management and restoration strategies in major railway projects.
Key words: major railway projects; ecological environment assessment; deep learning network; spectral characteristics; remote sensing; machine learning.

0 引言

生态环境是人类生存、经济发展和社会进步的基础(申艳军等, 2024).近年来我国在铁路工程建设方面大量投入,对生态环境产生较大扰动,尤其在我国西部区域,地形复杂、气候多样,孕育了丰富的生物多样性,同时生态系统自我调节能力较弱,生态环境的敏感性和变异性突出(Song *et al.*, 2024).面对重大工程扰动(图 1),部分地区出现了植被退化、土壤侵蚀加剧以及生物多样性减少等现象,对区域生态系统的稳定性和生态系统服务功能的发挥构成了威胁(宣炳旭等, 2025).因此,科学评估铁路工程建设对交通廊道区域生态环境质量的扰动,成为保障区域生态安全和实现可持续发展的关键(El-Husseini *et al.*, 2023; Arshad *et al.*, 2024).

早期的生态环境质量评价方法主要依赖现场调查和定性描述(Kaloyianni *et al.*, 2019; Kumar *et al.*, 2024).尽管后续发展出基于环境质量指数和生态环境质量指数等的多指标量化评价体系(Wen *et al.*, 2024),这类方法仍受限于数据时空分辨率较低,难以实现大范围、连续空间的交通廊道生态环境质量动态监测,尤其在西南山区铁路、公路等线性工程所形成的复杂生态系统中表现更为明显.随着数据挖掘、机器学习和深度学习技术的快速发展,以及多源遥感数据的普及,遥感与智能算法的融合逐渐成为交通廊道生态环境监测的重要方向(张兵, 2018; 王斌和范东林, 2019).例如,Matyukira *et al.*(2024)应用随机森林、支持向量机和神经网络等算法有效监测铁路和公路沿线植被动态,实时评估工程建设与气候变化对生态系统的影响.Xiao *et al.*(2022)基于无人机多光谱影像和堆叠集成学习算法对漳河水质进行监测,结果表明该模型在交通影响区水质参数提取中精度显著优于单一机器学习模型.Mohammadimanesh *et al.*(2019)提出一种面向极化 SAR 影像湿地分类的全卷积网络(Fully Convolutional Networks, FCN)架构,有效缓解了交通廊道周边 SAR 影像分类中的噪声与特征表达不足的难题.Ķēniņš(2020)利用 U-Net 卷积神经网络实现高分辨率遥感影像中森林、水体等地类的高精

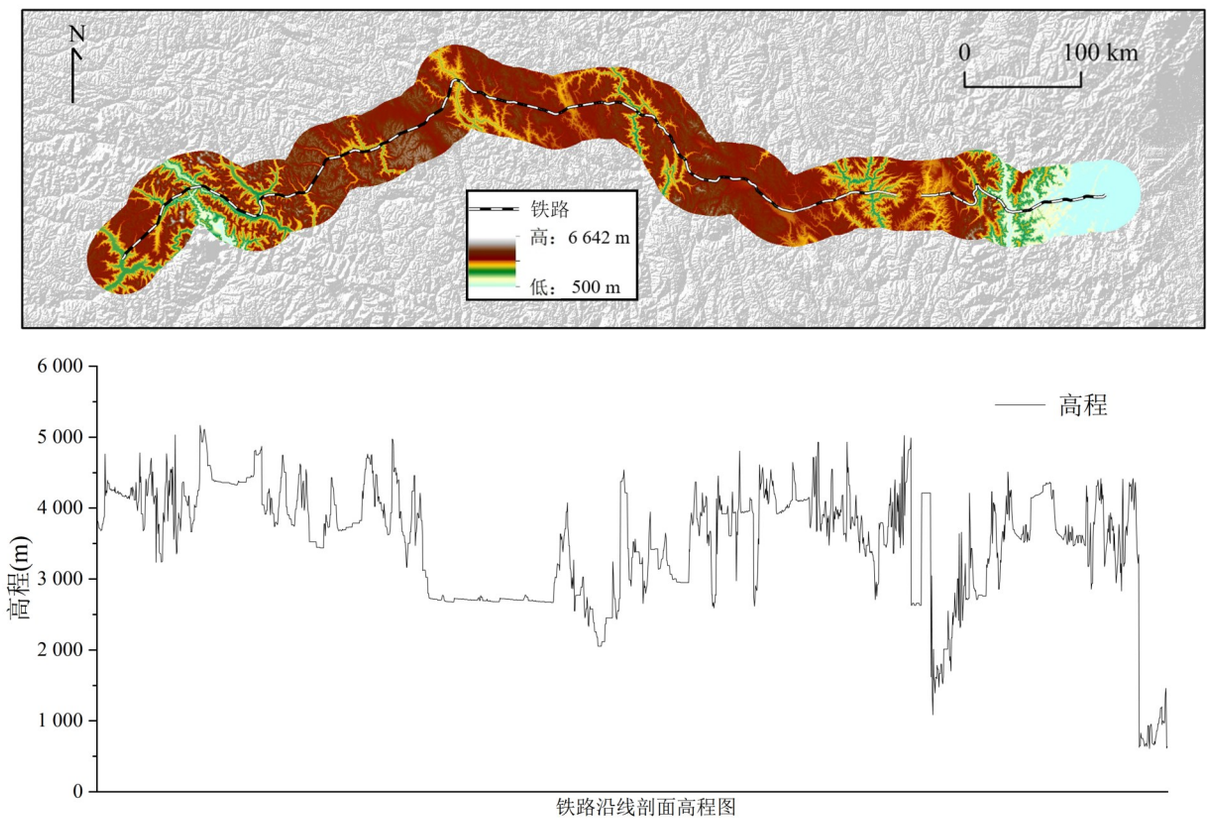


图 1　研究区地理位置及其高程状况

Fig.1　Geographical location and elevation of the study area

度分割,为交通基础设施建设中的土地利用与生态响应分析提供有力工具.这些研究显示了机器学习与深度学习在工程建设时期交通廊道遥感监测与生态评价中的广阔潜力,也为本文针对山区铁路工程开展高精度生态环境质量动态评价提供了重要借鉴.

然而,针对分布有高密度隧道工程、生态环境变化剧烈、空间异质性强的铁路交通廊道线性区域,现有评价方法仍面临诸多挑战:传统指标体系难以捕捉生态环境质量的快速动态变化;而多数机器学习和深度学习应用侧重于静态分类或特定参数反演,对廊道尺度连续时空动态监测的支持不足(Karisa *et al.*, 2020).尤其在我国高异质性的西部山区,实现精准的生态环境质量动态评价更具难度.此外,重大工程扰动在交通沿线呈现出“点-线-面”多元空间影响特征,既包括小范围的弃渣区、线性分布的施工便道,也包括大面积的施工区域,进一步加剧了空间尺度异质性带来的评价困难.现有方法多基于区域面状尺度的整体评价,缺乏能够统一覆盖“点-线-面”多类扰动形式的综合评价体系,导致对细微施工影响的识别与评估能力不足(Zhang *et al.*, 2020).

为突破上述局限,本文提出融合高时空分辨率 Sentinel-2 时序影像与深度学习语义分割模型的解决方案,通过构建面向评价任务的光谱特征数据集与 U-Net 等深度学习网络模型,并引入像元级光谱尺度评价方法,结合多期扰动检测机制,旨在实现对我国西部山区重大铁路交通廊道生态环境质量的高时空分辨率精准快速动态监测.该方法克服了传统方法在时空分辨率与动态评价能力上的不足,可有效识别微小施工影响区域,支持从像元到廊道尺度的全面生态环境影响评估.

1　研究区与数据

1.1　研究区概况

西南山区重大铁路工程正线长度 1 008.45 km,本文以正线 30 km 缓冲带为界作为研究区(图 1).该铁路沿线地形复杂多样,跨越盆地区、高山峡谷区、高原盆地区、横断山地区和河谷区共五个地貌单元.线路海拔变化显著,最低点约 500 m,

最高点超过5 000 m，海拔高差超过4 000 m.铁路沿线水系发达，跨越六大河流.

1.2 卫星遥感数据

Sentinel-2是欧洲空间局在哥白尼计划框架下开发的地球观测任务，旨在提供高分辨率的光学成像数据，涵盖可见光、近红外和短波红外波段，空间分辨率分别为10 m、20 m和60 m(Khosravi *et al.*, 2022).在本文中，通过Google Earth Engine(GEE)云平台获取Sentinel-2 Level-2A地表反射率(S2 SR)数据，筛选2019—2024年各年份5月至10月云量小于15%的影像，并采用质量控制波段对影像进行去云处理.随后通过计算归一化差异植被指数，采用NDVI质量镶嵌来合成每年Sentinel-2影像，用于后续植被、纹理指数的计算.

2 研究方法

本文采用Sentinel-2卫星遥感数据，对比U-Net、FCN和LinkNet语义分割模型在不同输入特征状态下的生态环境质量评价性能，从而构建基于深度学习耦合卫星影像光谱特征的生态环境评价模型，总体技术路线见图2.

2.1 特征分析

本文从Sentinel-2影像的光谱特征基础上衍生出三方面的特征，即单波段光谱特征、光谱指数特征及纹理特征.通过特征筛选来优化生态环境质量评价模型的性能.在特征选择过程中，结合了光谱特征的可分性分析、指数特征的生态环境指示作用和纹理特征的空间信息，确保最终选取的特征能够充分表征生态环境质量的差异性.

2.1.1 单波段光谱特征 单波段光谱特征在利用多光谱遥感影像进行生态环境质量评价中具有重要作用；不同地物在特定波段的光谱响应存在巨大差异，为生态环境质量等级的划分提供了科学依据.本研究基于Sentinel-2影像数据，初步筛选了B2(蓝光，490 nm)、B3(绿光，560 nm)、B4(红光，665 nm)、B5(红边，1 705 nm)、B6(红边，2 740 nm)、B7(红边，3 783 nm)、B8(近红外，842 nm)、B8A(窄近红外，865 nm)、B11(短波红外1，1 610 nm)、B12(短波红外2，2 190 nm)共10个波段.不同生态环境质量等级的光谱反射率曲线特征如图3所示，结合波段可分性及空间分辨率优势，最终确定B2、B3、B4及B8四个核心特征波段.

从光谱特征来看，蓝光波段(B2)对生态环境质

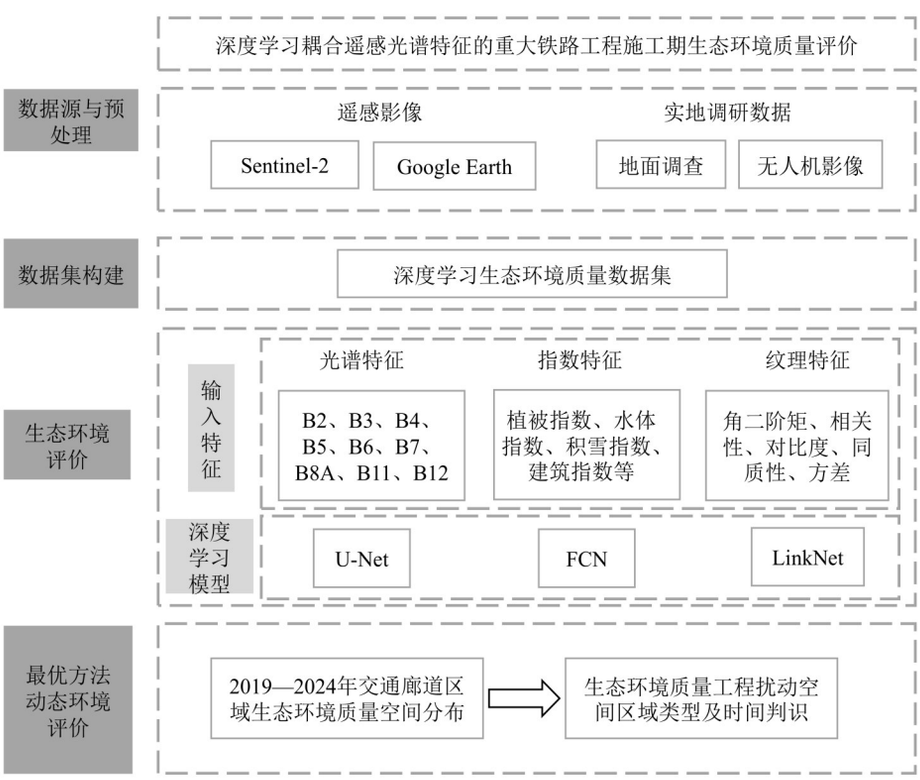


图2 技术路线图

Fig.2 Technology framework

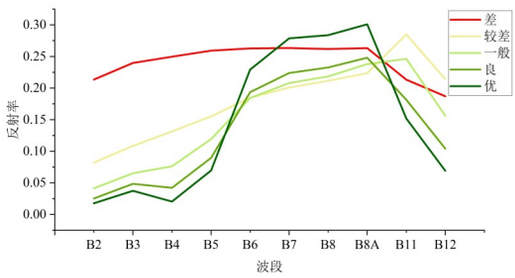


图3　不同生态环境质量等级波谱反射率曲线

Fig.3　Spectral reflectance curves for different environmental quality levels

量等级为差的响应敏感.生态环境质量等级为差的区域B2反射率显著高于其他等级,平均反射率在0.20以上.绿光波段(B3)在生态环境质量等级为优的区域呈现明显反射峰,而在生态环境质量等级为差的区域反射率曲线趋于平缓.这是因为该波段与植被叶绿素含量密切相关,健康植被因叶绿素含量高,对绿光具有高反射特性,而等级为优的区域相较于等级为差的区域植被长势好、植被覆盖度高.生态环境质量等级为优的区域红光波段(B4)反射率最低(约0.02),而在差等级区域反射率却在0.20以上.这是因为该波段是植被的主要吸收波段,植被覆盖度越高吸收越高反射则越低.近红外波段(B8)对植被细胞结构及生物量高度敏感,健康植被因细胞壁多次反射作用在B8处反射率显著增强,波段可分性突出.

由于要对研究区的生态环境质量进行高空间分辨率的评价,因此在研究光谱可分性的基础上还需要考虑光谱的空间分辨率.Sentinel-2影像的B2、B3、B4及B8波段均具备10 m空间分辨率,相较于其他波段(如B11、B12的20 m分辨率)能够更精细地刻画小型植被斑块、水体边界及人为干扰痕迹.

表1　基于Sentinel-2的光谱特征变量

Table 1　Variable characteristics of spectra based on Sentinel-2

变量类型	变量名称	描述	公式	参考文献
光谱信息	B2、B3、B4、B5、B6、B7、B8、B8A、B11、B12	Sentinel-2影像波段信息	\	\
植被指数	NDVI(归一化植被指数)	反映植被覆盖度和健康状况	$\frac{B8-B4}{B8+B4}$	Rouse *et al.*, 1974
	RENDVI(红边归一化植被指数)	反映植被覆盖度	$\frac{B6-B5}{B6+B5}$	Gitelson and Merzlyak, 1994
	EVI(增强型植被指数)	适用于植被密集地区的植被监测	$\frac{2.5\times(B8-B4)}{B8+6\times B4-7.5\times B2+1}$	Rouse *et al.*, 1974
	MSAVI(改进型土壤调节植被指数)	减少土壤背景影响,提高植被识别精度	$\frac{\left[2\times B8+1-\sqrt{(2\times B8+1)^2-8\times(B8-B4)}\right]}{2}$	Qi *et al.*, 1994
	NDWI(归一化水体指数)	反映水体分布和湿度状况	$\frac{B3-B8}{B3+B8}$	Gao, 1996
	NDMI(归一化湿度指数)	反映植被含水量,监测干旱状况	$\frac{B8-B11}{B8+B11}$	Jin *et al.*, 2005
	NDSI(归一化积雪指数)	主要用于积雪覆盖监测	$\frac{B3-B7}{B3+B7}$	Salomonson and Appel, 2004
	NDBI(归一化建筑指数)	识别城市建筑区域	$\frac{B7-B5}{B7+B5}$	Zha *et al.*, 2003
纹理指数	ASM(角二阶矩)	度量纹理均匀度,值高表面平滑	\	Haralick *et al.*, 1973
	Correlation(相关性)	度量灰度线性相关,值高结构连续	\	
	Contrast(对比度)	度量灰度反差,值高纹理粗糙	\	
	Homogeneity(同质性)	度量灰度同质性,值高纹理均一	\	
	Variance(方差)	度量灰度离散度,值高纹理复杂	\	

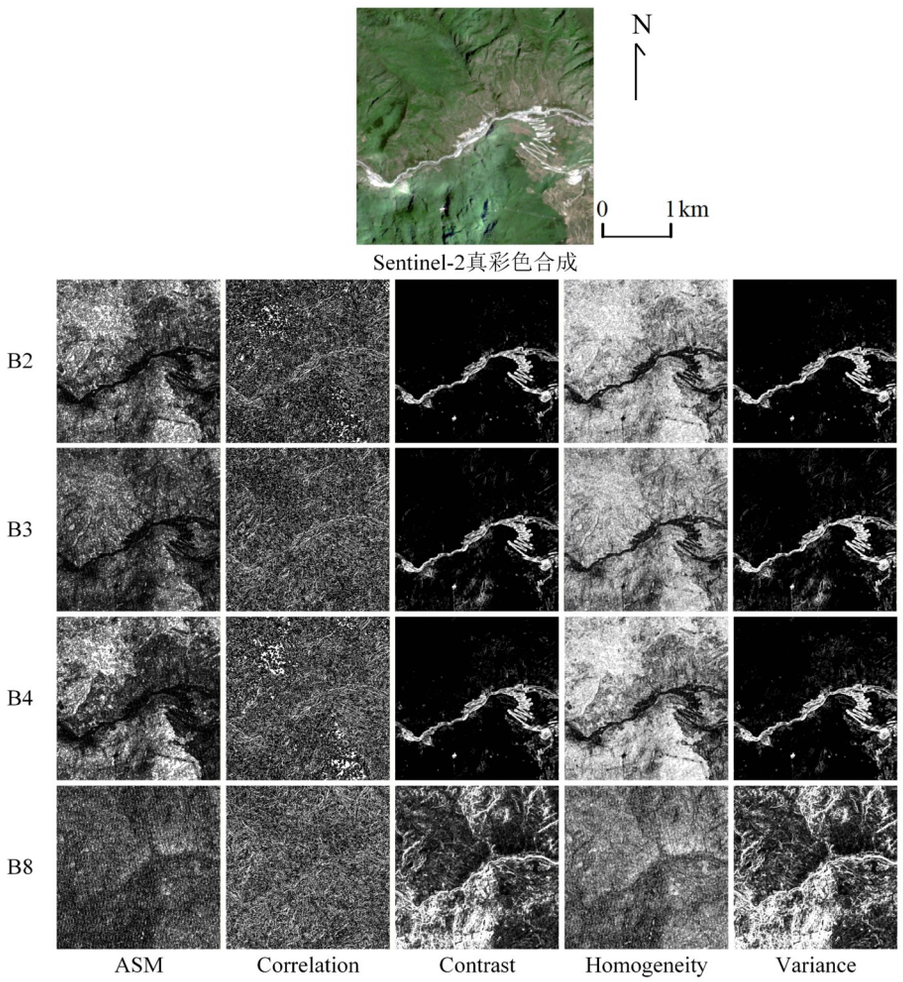


图 4 五类纹理特征示例

Fig.4 Representative examples of the five texture feature categories

虽然短波红外波段(B11、B12)的反射率在各生态环境质量等级间差异较大,但该波段分辨率较低(20 m)导致其在生态环境质量评价中的贡献有限.

2.1.2 光谱指数特征 光谱指数通过特定波段的组合,能够有效反映植被、水体、裸土等地物特征,从而提升对生态环境质量的识别能力.本文选择了 8 种常见的光谱指数,包括植被指数、湿度指数和建筑指数等来探讨光谱指数特征对评价结果的影响.具体光谱指数特征见表 1.

2.1.3 纹理特征 纹理特征主要用于描述影像的空间结构信息,能够增强对不同生态环境质量等级的识别能力.本文通过单波段光谱特征分析选择了 B2、B3、B4、B8 四个核心光谱波段.因此,在核心波段上计算灰度共生矩阵(GLCM),并提取其纹理特征,包括角二阶矩(ASM)、相关性(Correlation)、对比度(Contrast)、同质性(Homogeneity)和方差(Variance).局部影像与各纹理特征对比如图 4 所示,从不同波段角度看,B2、B3、B4 的纹理特征较为明显.另外从纹理特征看,对比度、同质性和方差对地物的纹理区分更明显,尤其是 B2、B3、B4 的此三类特征对于道路的区分愈加明显.因此,将 B2、B3、B4 波段的对比度、同质性和方差三类特征作为后续输入的纹理特征来辅助生态环境质量的分割.

2.2 生态环境评价方法

2.2.1 U-Net 模型 U-Net 最初由 Ronneberger *et al.*(2015)提出,用于生物医学图像分割,其 U 形对称结构使其在少量样本条件下也能实现高精度分割,因此被广泛应用于遥感影像中植被和水体等精细提取任务.该模型采用编码器-解码器架构:编码器通过卷积与池化提取深层特征,解码器通过上采样重建细节,并结合跳跃连接融合同尺度特征以缓解空间信息丢失(图 5).U-Net 能够融合多尺度局部细节与全局上下文,在复杂场景和细微结构分割中表现优越,通常以像素

级交叉熵损失进行训练,具有良好的泛化能力.

2.2.2　全卷积网络 FCN 模型　FCN是一种基于全卷积网络(Fully Convolutional Network,FCN)的语义分割模型,是一种典型的语义分割模型,它通过将传统CNN中的全连接层替换为卷积层,实现了对任意尺寸输入的端到端像素级预测(Shelhamer *et al.*, 2017).模型以VGG16为基础,通过多层卷积和池化提取高层语义特征,并利用反卷积恢复空间分辨率,同时通过跳跃连接融合浅层细节与深层语义,从而提升分割精度(图6).训练过程中采用交叉熵损失进行像素级监督,多尺度特征融合保证了模型在复杂场景下的鲁棒性.FCN被广泛应用于道路、建筑、植被等分割任务.

2.2.3　LinkNet 模型　LinkNet是一种轻量级语义分割模型(Chaurasia *et al.*, 2017),采用编码器-解码器结构,以ResNet提取特征,并通过逐层上采样恢复空间分辨率(图7);其核心创新是引入编码器与解码器的直接跳跃连接,用逐元素相加的方式传递特征,从而在降低计算量的同时有效减少信息丢失,实现了在保持较高分割精度的情况下具备实时处理能力,适用于自动驾驶、遥感和医学影像等场景.

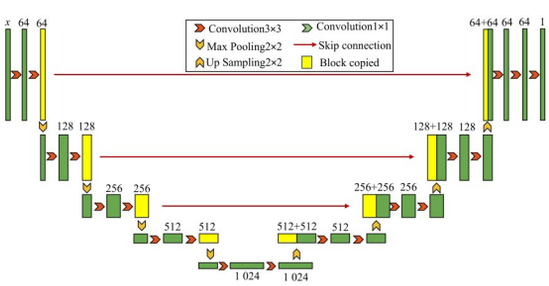


图5　U-Net网络架构

Fig.5　Schematic diagram of the U-Net architecture

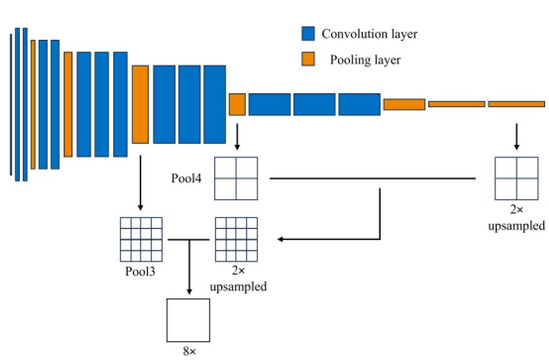


图6　FCN网络架构

Fig.6　Schematic diagram of the FCN architecture

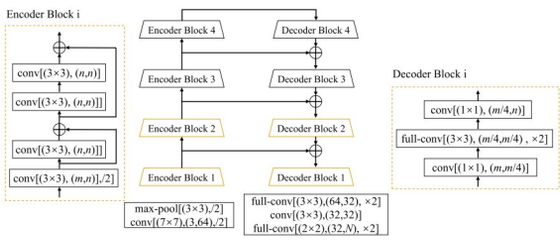


图7　LinkNet网络架构

Fig.7　Schematic diagram of the LinkNet architecture

2.3　样本标签制作

基于Sentinel-2卫星遥感影像(10 m),样本尺寸统一为256×256像素(对应实地尺度2 560 m×2 560 m),共生成500个样本.标注过程严格保证空间分布均衡性与类别典型性,以规避训练偏差.采用ESA 10 m全球土地利用数据(https://esa-worldcover.org/en/worldcover/),依据土地类型映射至生态环境质量等级,并通过NDVI、NDWI等关键指数阈值分割实现等级精细化划分(Magidi *et al.*, 2021; Namazi *et al.*, 2023).在满足阈值条件的区域内进行随机均衡采样,生成600个补充样本.对自动扩充样本实施人工抽样质检,验证其与原始影像的一致性,避免因阈值偏差导致的误标注;同时检验类别分布均衡性,防止模型过拟合.最终构建包含1 100个样本的数据集,其中训练集880个样本,验证集和测试集各110个样本.

2.4　调查及验证数据获取

野外调研于2022年7月1日至7月30日以及2023年7月13日至27日开展,聚焦部分已有弃渣场区域,以获取其周边生态环境的基础数据,同时掌握弃渣场对周边生态环境具体影响的实地信息.主要调查实地点生态环境质量等级,而对于部分抵近困难区域采用大疆无人机(DJI PHANTOM 4 RTK)获取生态环境质量信息,两种方式共获取样本点63个(图8a、图8b).由于受研究区海拔高、地形复杂等特殊地理条件限制,野外调研和无人机遥测收集的样本非常有限.为确保样本集的代表性与合理性,在构建过程中样本点通过ArcGIS在研究区内随机生成,以保证空间分布的均匀性,并针对核心施工区域进行了加密布设;其次,样本类别设计涵盖了施工区与非施工区的所有典型地物;最后,设定了合理的施工区与非施工区样本比例,以服务于评估人类活动影响的核心目标.样本解译过程与实地无人机遥测获取生态环境质量等级一致(图8d),其判定严格遵循统一的分类标准,从而确保了

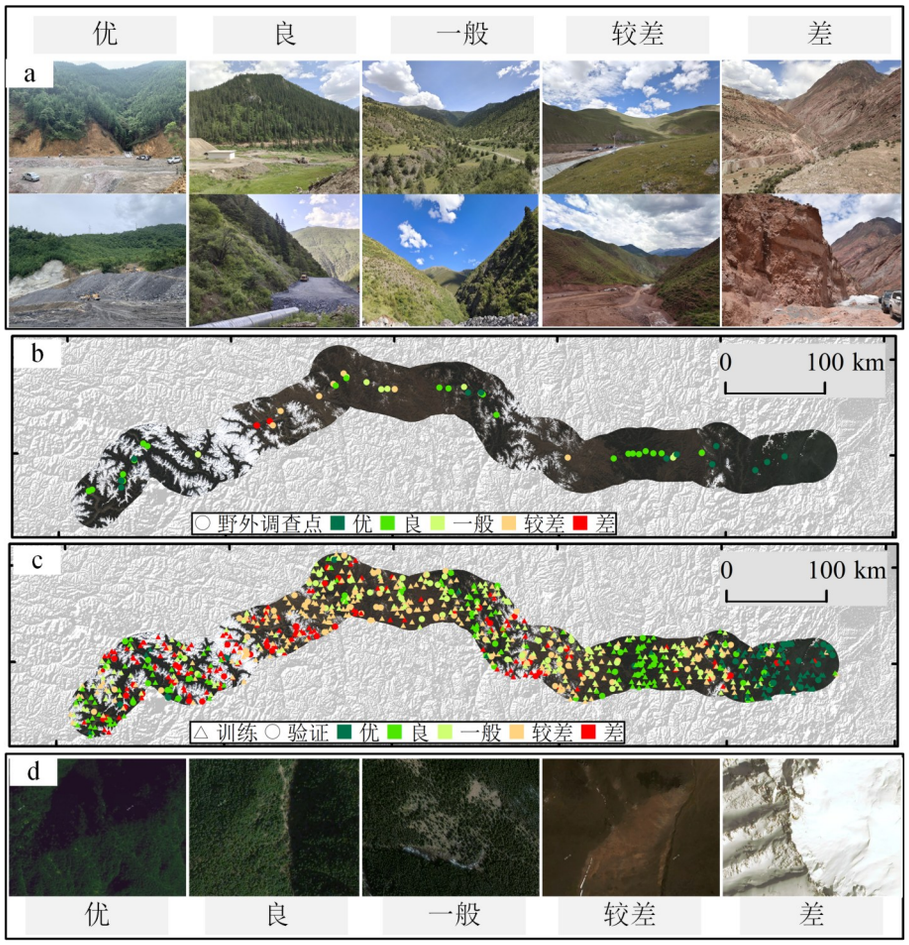


图 8 生态环境质量等级样本分布与实地立地景观

Fig.8 Distribution of environmental quality grade samples and the corresponding field landscapes

a. 实地调研照片；b. 调研点；c.Google Earth 目视解译样本点；d.Google Earth 高清影像

样本解译的准确性与一致性. 最终通过目视解译获取样本 978 个(图 8c).

2.5 精度验证方法

为了能够全面评估模型性能，采用三个核心评价指标即测试集准确率(Test Accuracy)、平均交并比(Mean IoU)和宏 F1 分数(Macro F1 Score)进行评价. 各指标及计算方法如下.

$$\text{Accuracy}=\frac{\sum_{k=1}^{K}\text{Correct}_k}{N_{\text{test}}}\times 100\%, \quad (1)$$

$$\text{Mean Iou}=\frac{1}{K}\sum_{k=1}^{K}\frac{TP_k}{TP_k+FP_k+FN_k}\times 100\%, \quad (2)$$

$$\text{Macro F1}=\frac{1}{K}\sum_{k=1}^{K}\left(2\frac{P_k\times R_k}{P_k+R_k}\right)\times 100\%, \quad (3)$$

$$\text{Precision}_k=\frac{TP_k}{TP_k+FP_k}, \quad (4)$$

$$\text{Recall}_k=\frac{TP_k}{TP_k+FN_k}, \quad (5)$$

其中，Correct_k 表示第 k 类正确预测的像素数，N_{test} 为测试集总像素数，K 为类别总数，TP_k、FP_k、FN_k 分别为第 k 类的真阳性、假阳性和假阴性像素数量.

3 结果与讨论

3.1 特征选择与模型建立

基于 Sentinel-2 MSI 影像，本文构建了一套耦合光谱-指数-纹理多维特征的环境质量遥感判别体系(Akhtar *et al.*, 2020; Santana *et al.*, 2025). 三者协同，实现了光谱可辨性、生态指示意义与空间异质信息的有机融合，为后续语义分割模型奠定了高判别力特征基准. 为研究不同维度特性对生态环境质量分析的效果，本文将光谱信息、植被指数、纹理指数三类特征组合成 5 种不同的形式(表 2).

将 5 种不同的特征组合方式分别输入到 FCN、U-Net 和 Link-Net 模型，采用构建的数据集进行训练，数据集中训练集、验证集、测试集的划分比例为

表 2　特征参量组合

Table 2　Feature parameter combination

序号	特征参量组合
a	光谱信息 1(B2、B3、B4、B5、B6、B7、B8、B8A、B11、B12波段)
b	光谱信息 2(B2、B3、B4、B8波段)
c	植被指数
d	光谱信息 2(B2、B3、B4、B8波段)＋植被指数
e	光谱信息 2(B2、B3、B4、B8波段)＋植被指数＋纹理特征

8∶1∶1.模型参数设置如表 3 所示.在模型训练中,样本输入大小为 256 像素×256 像素,此像素大小可以聚焦局部纹理与光谱特征、提升小尺度地物的识别精度,同时 2 560 m×2 560 m 可覆盖典型地物完整结构,避免异质混杂.

3.2　三种方法模型评估结果精度验证

模型架构的选择对性能表现具有决定性影响,其主导性远超输入特征的微调优化,通过三种模型获取的生态环境质量结果见图 9 及表 4.图 9 展示了三种模型在精度最高的输入特征组合下所得到的 2021 年生态环境质量等级空间分布结果.三个模型评价结果在空间分布上具有极高的一致性,生态环境质量都大体呈现出东西两端高、中间低的分布格局,同时呈现出宏观分散、局部集中的空间分布特性,空间异质性明显.U-Net 在全部评估指标上展现出对 FCN 的系统性优势——其在特征组合 d 下达到的准确率(91.65%)与平均交并比(84.72%)显著超越 FCN 于任何输入配置下的最优结果(准确率峰值:82.95%;mIoU 峰值:70.84%).机理分析表明:U-Net 通过编码器-解码器架构中嵌入的跳跃连接,实现了跨尺度语义特征的协同融合与空间细节的高保真重建;反观 FCN,因缺失显式的多级特征整合机制,在输入扰动下仅诱发 0.61% 的准确率波动,揭示其对特征扰动的低响应特性.尽管 U-Net 与 LinkNet 均采用跳跃连接,但是 U-Net(~31.0 M 参数)凭借更强的表征能力,提供了更高的精度与稳定性;而 LinkNet(~7.8 M 参数)则偏向效率但稳定性欠佳.值得注意的是,LinkNet 在特征组合 c 下呈现非预期性能跃升(准确率:90.23%),印证了其轻量级架构对特定数据分布较为敏感的特性.LinkNet 虽在特定特征输入下取得了较高的精度,但其预测结果存在明显的空间水平纹理,影响了空间连续性.

U-Net 模型揭示了输入特征维度与精度间的非单调依赖关系:12 维特征组合(B2、B3、B4、B8 与光谱指数叠加)在特征组合 d 下达到峰值性能(Accuracy:91.65%),而扩展至 13 维时因特征冗余导致精度显著下降(89.73%).另外,8 维纯光谱指数输入(特征组合 c)的性能衰减证实 B2 波段对生态纹理表征的不可替代性.尽管 FCN 与 LinkNet 在特征组合 c 下同步出现性能折损,LinkNet 却在该配置下呈现异常提升(Accuracy:90.23%),表明其解码路径对抽象指数语义具有架构特异性响应.特征组合 d 的性能优势源于原生波段与光谱指数的协同效应——光谱指数通过增强判别性光谱特征而非取代原始响应,使模型在复杂生态环境质量评估中实现最优性能.

3.3　生态环境质量在 FCN、U-Net、LinkNet 模型下的差异性分析

U-Net、FCN 与 LinkNet 在各自最优特征输入下所绘生态质量格局呈东西高、中间低的宏观分异,如图 10 所示,植被覆盖密集区域连片“优”级,植被稀疏区域则聚为“差”级,局部破碎化显著.图 10 的等级占比揭示,三个模型均以“较差”级为主、“差”级占比最少,但 FCN 倾向压缩“优”与“一般”而向“良”级集中,U-Net 与 LinkNet 则在“优”与“一般”两端扩张,其中 LinkNet 的“优”级略低于 U-Net,而

表 3　模型参数

Table 3　Model parameters

参数名称	参数取值	描述
样本批量大小	16	每次训练输入模型的样本数量
迭代次数	100	总训练轮数
随机数种子	42	用于保证实验可重复性
学习率	0.001	初始学习率
学习率调度器	若连续 3 次迭代精度不增加,则学习率缩小为一半	动态调整学习率的策略
早停机制	若连续 6 次迭代精度不增加,则结束训练	防止过拟合的机制

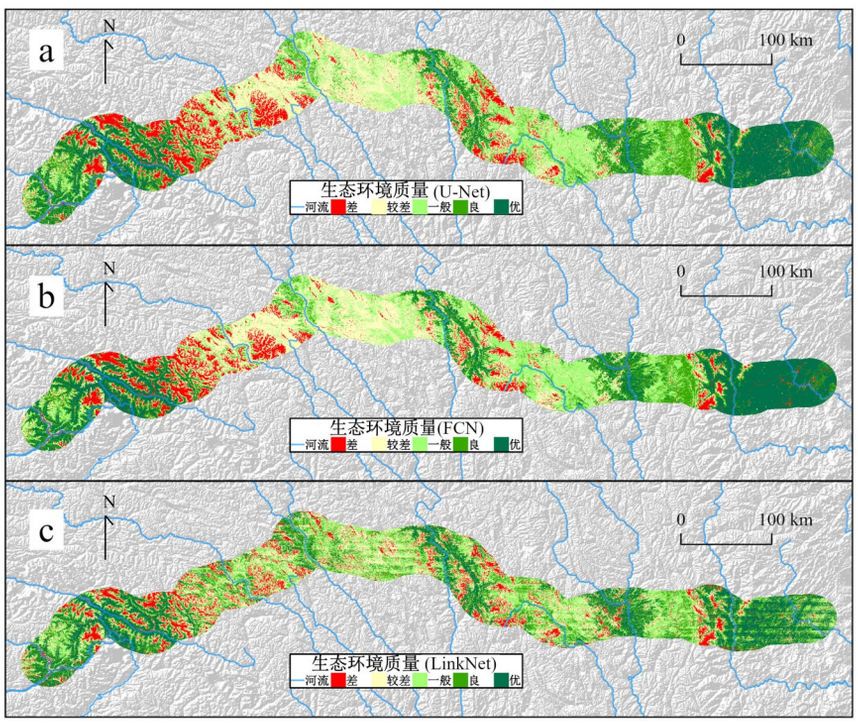


图 9 FCN、U-Net、LinkNet模型生态环境质量评价结果

Fig.9 Eco-environmental quality assessment results of FCN, U-Net and LinkNet models

表 4 不同特征组合形式评价结果精度

Table 4 Evaluation results of metrics for different feature input schemes

模型名称	特征组合	Accuracy (%)	Mean IoU (%)	Macro F1 Score (%)
U-Net	**a**	**91.26**	**84.09**	**91.23**
	b	90.53	82.87	90.45
	c	90.46	82.75	90.40
	d	**91.65**	**84.72**	**91.58**
	e	89.73	81.40	89.59
FCN	a	82.95	70.84	82.76
	b	82.85	70.66	82.63
	c	82.34	69.87	82.07
	d	82.89	70.67	82.64
	e	82.42	70.00	82.16
LinkNet	a	80.37	66.72	79.93
	b	83.50	71.10	83.03
	c	**90.23**	**82.22**	**90.11**
	d	89.92	81.72	89.80
	e	81.78	68.94	81.50

“良”级略高,暗示其判别边界略保守.图 11 的可视化对比进一步揭示模型架构之间的差异:FCN因受限的感受野与上采样过程中的信息损失,导致交通廊道与裸地被错误归类为同质区域;LinkNet虽引

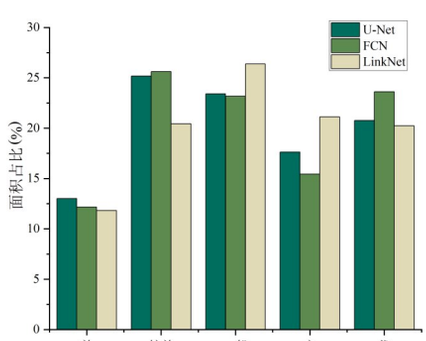


图 10 FCN、U-Net、LinkNet模型评价等级面积占比

Fig.10 Area proportions for quality classes derived from FCN, U-Net and LinkNet models

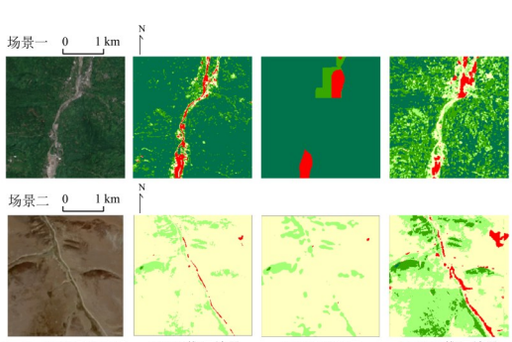


图 11 FCN、U-Net、LinkNet模型评价结果局部对比

Fig.11 Local comparison of evaluation results between FCN, U-Net and LinkNet models

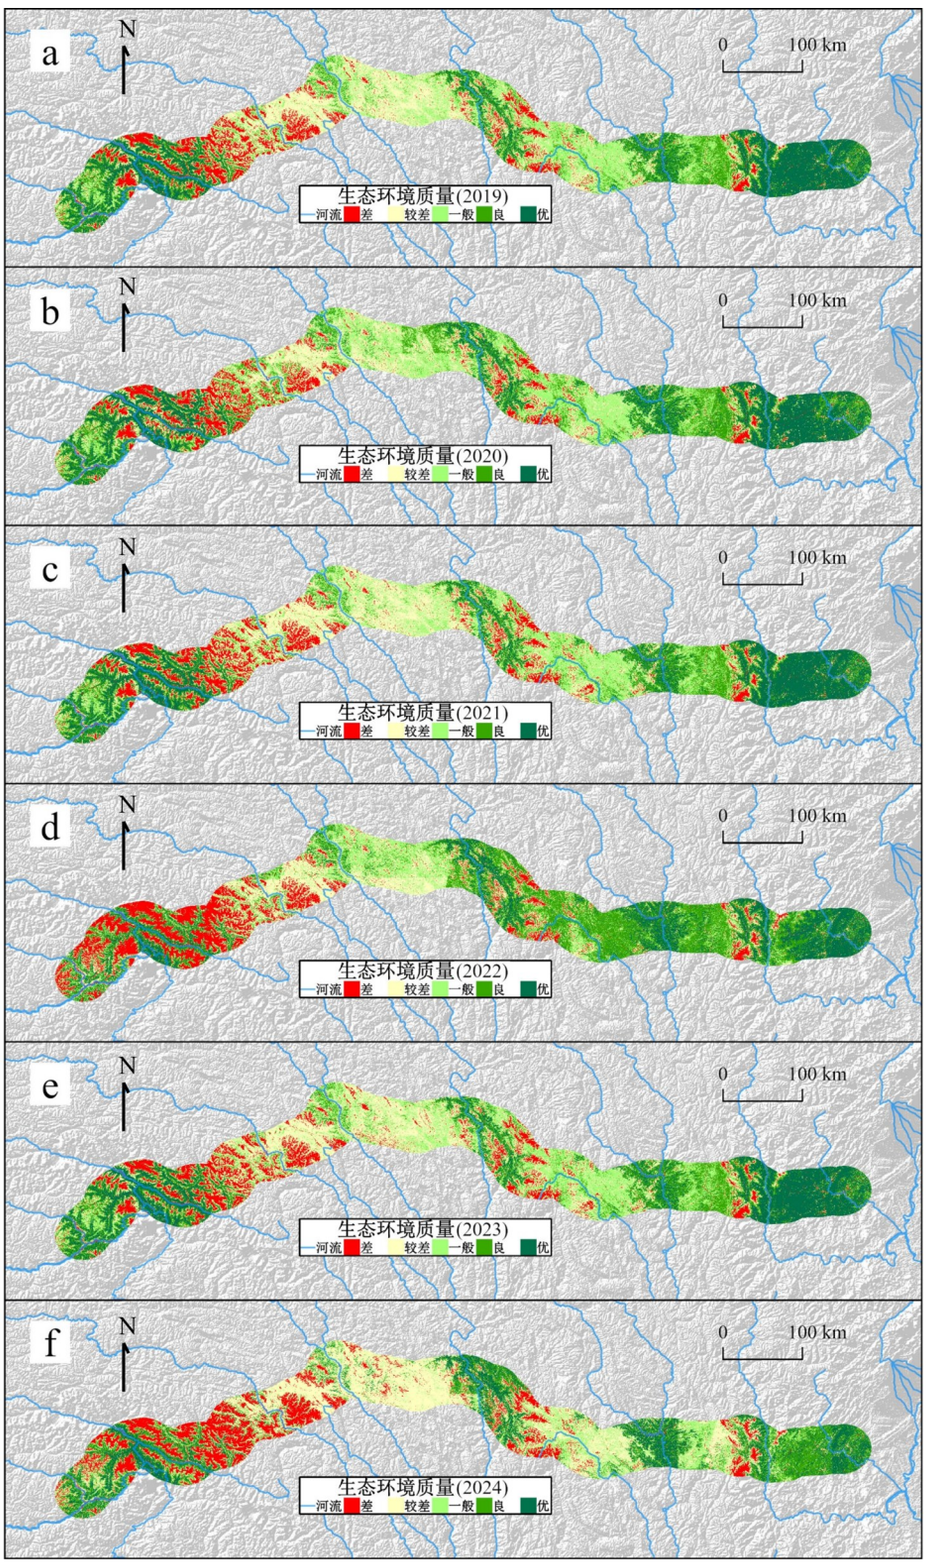


图 12　2019－2024 年生态环境质量评价空间分布

Fig.12　Spatial distribution of eco-environmental quality assessment from 2019 to 2024

入跳跃连接,但其解码路径的梯度传播缺陷加剧了窄长线状地物的空间不连续性;相比之下,U-Net 通过多尺度特征融合与精确的跳跃连接机制,在维持复杂边界结构完整性方面展现显著优势(仅存零星线状断裂).该空间一致性优势与表 4 量化指标相互印证,证实 U-Net 在破碎化生态景

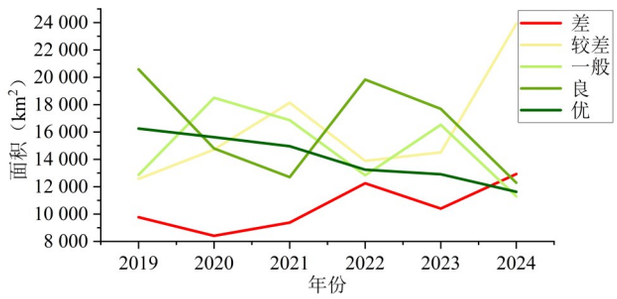


图 13 2019－2024 年不同生态环境质量等级面积变化曲线

Fig.13 Temporal curves of area changes across different eco-environmental quality classes from 2019 to 2024

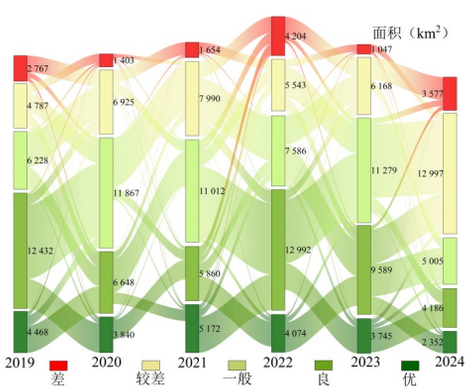


图 14 2019－2024 年不同生态环境质量等级转移图

Fig.14 Transition maps of different eco-environmental classes from 2019 to 2024

观解析中具有最优的几何保真能力.

3.4 交通廊道生态环境动态变化分析

3.4.1 生态环境质量年际空间分布 基于三种模型在不同特征组合方式下的性能比较,本研究最终选择 U-Net 模型结合特征组合 d 的形式对交通廊道生态环境进行时序评估.得到的 2019－2024 年生态环境质量等级空间分布结果如图 12 所示.2019－2024 年间,生态质量沿交通廊道呈“低海拔优、高海拔劣”的垂直地带性格局.生态劣级区域主要分布于雪线以上的寒漠地带;优级生态区则集中于常绿阔叶林低山区域.在过渡区域,以灌草植被为主的较差与一般等级地段呈现明显的季节性和年际波动,频繁发生等级转换,反映出水热条件与土壤-植被耦合作用对生态系统稳定性的关键影响.进一步分析表明,这种垂直地带性格局及其波动特征,相较于已有研究(Zhang *et al.*, 2015)在横断山区进行的评估,具有更高的空间细节分辨能力和时序连续性,清晰地刻画出交通廊道这一线性工程影响下的生态梯度变化细节.

3.4.2 生态环境质量变化分析 利用构建的最优模型,对 2019－2024 年研究区生态环境质量进行时序评估,结果见图 12,并绘制出各生态等级面积变化曲线(图 13).分析表明,生态质量展现出明显的阶段性变化与复杂性.尤为突出的是,优等级面积从 2019 年的 16 250 km²急剧下降至 2024 年的 11 627 km²,下降 28.5%,表明区域生态质量存在明显的退化趋势.此外,一般和良等级面积的年际波动剧烈,主要受西南山区气候波动、交通建设对植被的破坏及区域开发活动的影响.

区域生态环境质量等级年际转移桑基图(图 14)深入揭示出 2019－2024 年研究区生态环境质量等级的动态演替.其中一般等级向较差,以及良向一般等级的转换占据主导,映射出区域生态质

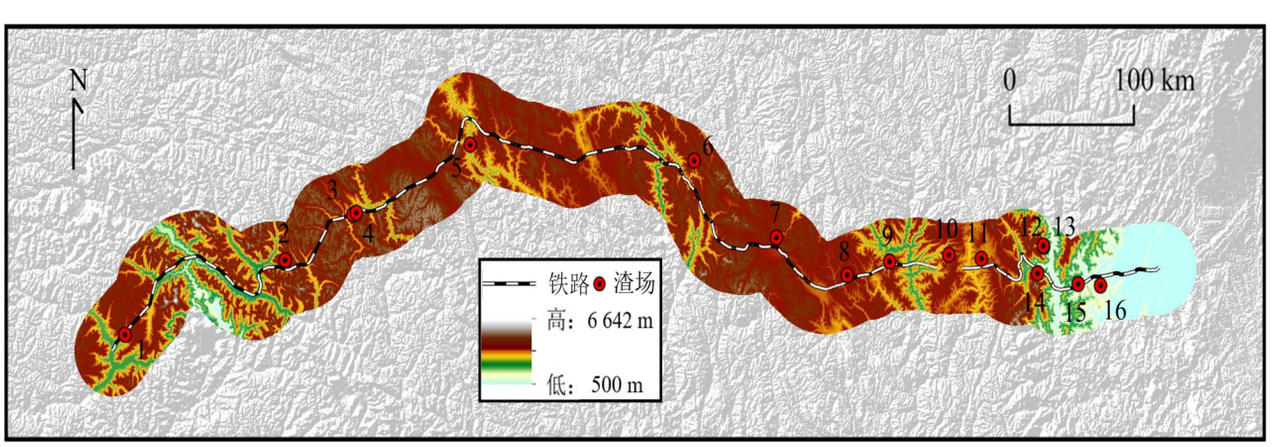


图 15 弃渣场位置

Fig.15 Location of spoil disposal sites

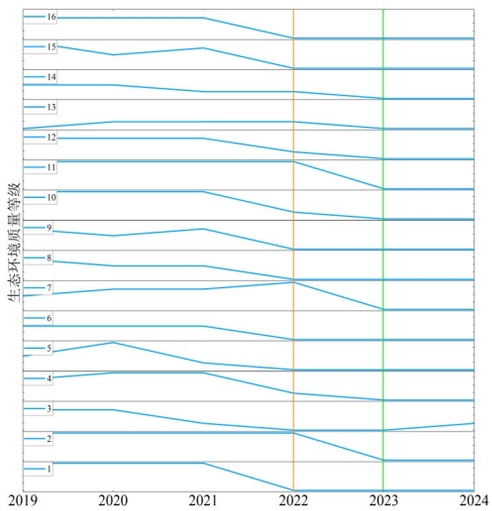


图 16　弃渣场区域生态环境质量等级变化曲线

Fig.16　Curves in the ecological environment quality rating of the waste disposal site area

量的总体下降趋势.2021 至 2022 年期间,一般和良等级向差等级的显著转换,与该铁路交通廊道在此期间进入高强度施工阶段高度吻合.这一发现深化了 Wang *et al.*(2025)指出工程活动导致生态退化的认知,本研究不仅确认了干扰的存在,更精确地识别出干扰发生的关键时段和主导的生态等级转换类型,揭示了工程扰动下生态质量退化的具体路径.研究时段内,生态质量在持续退化,而良和优等级间的转换则相对稳定.

3.5　交通廊道工程扰动对生态环境影响分析

为深入研究交通廊道中工程扰动对生态环境的影响,本研究随机选取铁路交通廊道沿线规划的 16 个弃渣场作为工程扰动区域(图 15),对渣场点的生态环境质量等级变化进行分析.如 2019—2024 年的生态环境质量变化曲线(图 16)所示,黄色竖线表示多数渣场在 2022 年生态环境

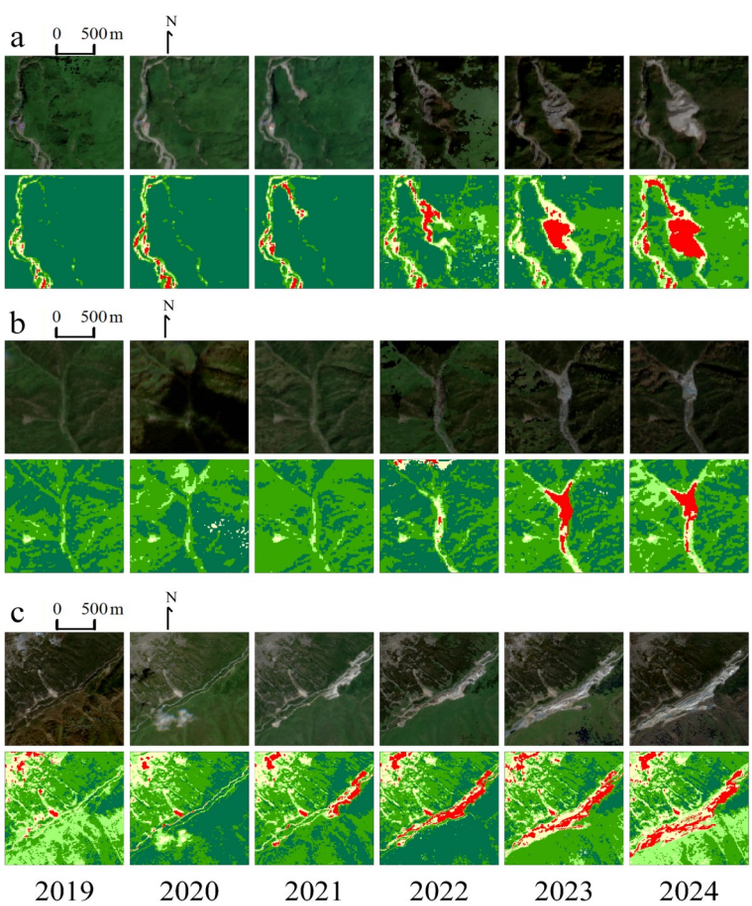


图 17　2019—2024 年弃渣场区域 Sentinel-2 真彩色与生态环境质量评价变化图

Fig.17　Changes in Sentinel-2 true-color composites and eco-environmental quality assessment for waste dump sites from 2019 to 2024

a.平坡弃渣场;b.斜坡弃渣场;c.集中弃渣场

质量出现明显下降，绿色竖线则表示2023年其质量进一步退化至“差”等级.可以发现自2020年铁路工程开工以来，绝大多数渣场所在区域的生态环境质量迅速退化至差等级，直接证明了工程扰动将显著降低生态环境质量（王德智等，2015）.然而，本研究通过高时空分辨率监测，进一步发现了不同渣场生态响应的异质性及其与施工进度的关联，对现有知识进行了补充.

本研究表明，西南山区交通廊道工程在推动区域社会经济发展的同时，也对生态环境造成了多维度的显著扰动.首先，在土地利用与景观格局层面，廊道建设导致耕地、林地和草地的直接占用，引发了带状屏障效应，加剧景观破碎化和生态连通性下降（Zhou and Song, 2021）.生态系统结构的改变不仅表现为空间格局的破碎，还通过边缘效应引发栖息地质量下降，从而对区域生态安全构成威胁（Yadav *et al.*, 2024）.其次，在水文与土壤方面，工程基础开挖和场地平整深刻改变了地表径流与地下水补给过程，施工扰动造成土壤严重压实和侵蚀加剧，局部地区出现干旱与积水并存的现象，同时增加了面源污染与地下水潜在污染风险（Tsegaye *et al.*, 2022）.此外，交通廊道扰动还表现为生态系统服务功能的衰退，例如碳汇能力减弱、土壤保持与水源涵养功能退化.

为了进一步证明结果的可靠性，选择典型平坡、斜坡和集中弃渣场三处弃渣场进行局部空间分析.三处弃渣场在不同年份的Sentinel-2真彩色图像与生态环境质量评价结果如图17所示.通过对比分析，可以直观地辨识出各弃渣场的开始堆渣时间（分别为2022年、2022年和2021年）及其堆渣范围的动态扩张过程.验证了遥感手段在监测工程活动时序上的有效性，更重要的是，它揭示了不同工程节点产生的扰动在时间和空间上并非同步，其生态影响强度与渣场规模和启用时间密切相关.

4 结论

本文针对西南山区跨越复杂地形路段铁路交通廊道生态环境质量动态监测需求，创新性地融合高时空分辨率Sentinel-2影像与深度学习语义分割技术，系统构建了一套适用于地形复杂、生态敏感、景观破碎区域的生态环境质量评价方法，揭示了交通工程建设扰动下的生态环境质量演变规律与机制.主要结论如下：

（1）基于Sentinel-2影像输入关键光谱波段（B2、B3、B4、B8）与8项光谱指数组合特征，并采用U-Net模型，可取得最优生态环境质量评价效果，测试集精度高达91.65%，显著优于FCN（82.95%）和LinkNet（90.23%），该网络模型结合光谱波段特征更鲁棒可靠，可为大范围交通廊道区域的生态环境质量提供高空间分辨率的动态监测.

（2）2019—2024年时序评价结果表明研究区生态环境质量呈现“东西高、中间低”的稳定空间分异格局，在交通廊道尺度上精细刻画了“低海拔优、高海拔劣”的垂直地带性分布细节，深化了对横断山区生态梯度规律的认识.

（3）时序分析表明区域生态环境质量总体呈退化趋势，优等区面积在5年间显著减少28.5%，且生态等级转移分析（一般→较差、良→一般）进一步证实了这一主导退化过程.精准识别出2021—2022年铁路主体施工期为生态退化的关键时期，质量指数下降0.18.在此期间生态质量的急剧恶化与西南山区铁路建设活动密切相关，工程扰动将显著降低生态环境质量.

（4）通过对弃渣场等典型工程节点的分析，发现了工程扰动在时空上具有显著的异质性，其影响强度与具体工程节点的进度密切相关.这一规律突破了将工程扰动视为均质整体的传统认知，为重大线性工程实施“分区、分期”的生态精准管控与动态修复提供了关键的科学依据.

综上所述，本文所建立的融合遥感与深度学习网络的方法体系，显著提升了复杂山区交通廊道生态环境动态监测的精度与效率，精准识别了工程扰动引起的区域生态质量退化与演变趋势，为交通廊道规划、施工及运营期的生态风险精准识别、动态评估与防控提供了重要的技术支撑.

References

Akhtar, A. M., Qazi, W. A., Ahmad, S. R., et al., 2020. Integration of High-Resolution Optical and SAR Satellite Remote Sensing Datasets for Aboveground Biomass Estimation in Subtropical Pine Forest, Pakistan. *Environmental Monitoring and Assessment*, 192(9): 584. https://doi.org/10.1007/s10661-020-08546-1

Arshad, F., Iqbal, M., Riaz, A., et al., 2024. Road Corridors Vegetation in the Semi-Arid Region: Functional Trait Diversity and Dynamics. *Scientific Reports*, 14:

25212. https://doi.org/10.1038/s41598-024-76484-w

Chaurasia, A., Culurciello, E., 2017. LinkNet: Exploiting Encoder Representations for Efficient Semantic Segmentation. 2017 IEEE Visual Communications and Image Processing (VCIP). St. Petersburg. https://doi. org/10.1109/vcip.2017.8305148

El-Husseini, H., Chowyuk, A. N., Gustafson, R. R., et al., 2023. Roadside Vegetated Filter Strips to Simultaneously Lower Stormwater Pollution Loadings and Improve Economics of Biorefinery Feedstocks. *Journal of Environmental Management*, 347: 119168. https://doi. org/10.1016/j.jenvman.2023.119168

Gao, B. C., 1996. NDWI: A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water from Space. *Remote Sensing of Environment*, 58(3): 257—266. https://doi. org/10.1016/S0034-4257(96)00067-3

Gitelson, A., Merzlyak, M. N., 1994. Spectral Reflectance Changes Associated with Autumn Senescence of Aesculus Hippocastanum L. and Acer Platanoides L. Leaves. Spectral Features and Relation to Chlorophyll Estimation. *Journal of Plant Physiology*, 143(3): 286—292. https://doi.org/10.1016/S0176-1617(11)81633-0

Haralick, R. M., Shanmugam, K., Dinstein, I., 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6): 610—621. https://doi.org/10.1109/TSMC.1973.4309314

Jin, S. M., Sader, S. A., 2005. Comparison of Time Series Tasseled Cap Wetness and the Normalized Difference Moisture Index in Detecting Forest Disturbances. *Remote Sensing of Environment*, 94(3): 364—372. https://doi.org/10.1016/j.rse.2004.10.012

Kaloyianni, M., Feidantsis, K., Nteli, I., et al., 2019. Biochemical and Molecular Responses of Cyprinids in Two Mediterranean Lacustrine Ecosystems: Opportunities for Ecological Assessment and Biomonitoring. *Aquatic Toxicology*, 211: 105—115. https://doi. org/10.1016/j.aquatox.2019.03.021

Karisa, J. F., Obura, D. O., Chen, C. A., 2020. Spatial Heterogeneity of Coral Reef Benthic Communities in Kenya. *PLoS One*, 15(8): e0237397. https://doi. org/10.1371/journal.pone.0237397

Ķēniņš, R., 2020. Land Cover Classification Using very High Spatial Resolution Remote Sensing Data and Deep Learning. *Latvian Journal of Physics and Technical Sciences*, 57(1—2): 71—77. https://doi.org/10.2478/lpts-2020-0009

Khosravi, V., Gholizadeh, A., Saberioon, M., 2022. Soil Toxic Elements Determination Using Integration of Sentinel-2 and Landsat-8 Images: Effect of Fusion Techniques on Model Performance. *Environmental Pollution*, 310: 119828. https://doi. org/10.1016/j.envpol.2022.119828

Kumar, A., Kumar, P., Patil, M., et al., 2024. Disturbance and Vegetational Structure in an Urban Forest of Indian Siwaliks: An Ecological Assessment. *Environmental Monitoring and Assessment*, 196(8): 691. https://doi.org/10.1007/s10661-024-12801-0

Magidi, J., Nhamo, L., Mpandeli, S., et al., 2021. Application of the Random Forest Classifier to Map Irrigated Areas Using Google Earth Engine. *Remote Sensing*, 13(5): 876. https://doi.org/10.3390/rs13050876

Matyukira, C., Mhangara, P., 2024. Advances in Vegetation Mapping through Remote Sensing and Machine Learning Techniques: A Scientometric Review. *European Journal of Remote Sensing*, 57(1): 2422330. https://doi.org/10.1080/22797254.2024.2422330

Mohammadimanesh, F., Salehi, B., Mahdianpari, M., et al., 2019. A New Fully Convolutional Neural Network for Semantic Segmentation of Polarimetric SAR Imagery in Complex Land Cover Ecosystem. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151: 223—236. https://doi.org/10.1016/j.isprsjprs.2019.03.015

Namazi, F., Ezoji, M., Parmehr, E. G., 2023. Paddy Rice Mapping in Fragmented Lands by Improved Phenology Curve and Correlation Measurements on Sentinel-2 Imagery in Google Earth Engine. *Environmental Monitoring and Assessment*, 195(10): 1220. https://doi. org/10.1007/s10661-023-11808-3

Qi, J., Chehbouni, A., Huete, A. R., et al., 1994. A Modified Soil Adjusted Vegetation Index. *Remote Sensing of Environment*, 48(2): 119—126. https://doi. org/10.1016/0034-4257(94)90134-1

Ronneberger, O., Fischer, P., Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015. Springer, Cham, 234—241.

Rouse, J. W., Haas, R. H., Schell, J. A., et al., 1974. Monitoring Vegetation Systems in the Great Plains with ERTS. *NASA Special Publication*, 351(1), 309—317.

Salomonson, V. V., Appel, I., 2004. Estimating Fractional Snow Cover from MODIS Using the Normalized Difference Snow Index. Remote Sensing of Environment, 89(3): 351—360. https://doi.org/10.1016/j.rse.2003.10.016

Santana, F. C., Francelino, M. R., Siqueira, R. G., et

al., 2025. Sentinel-2 Imagery Coupled with Machine Learning to Modelling Water Turbidity in the Doce River Basin, Brazil. Environmental Monitoring and Assessment, 197(4): 459. https://doi. org/10.1007/s10661-025-13918-6

Shelhamer, E., Long, J., Darrell, T., 2017. Fully Convolutional Networks for Semantic Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(4): 640－651. https://doi.org/10.1109/TPAMI.2016.2572683

Shen, Y. J., Chen, X., Peng, J. B., et al., 2024. Background Characteristics of Ecological Geological Environment System in Qinling Mountains and Assumption of Its Theoretical System. Earth Science, 49(6): 2103－2119 (in Chinese with English abstract).

Song, S., Wang, S. H., Gong, Y., et al., 2024. The Past and Future Dynamics of Ecological Resilience and Its Spatial Response Analysis to Natural and Anthropogenic Factors in Southwest China with Typical Karst. Scientific Reports, 14: 19166. https://doi.org/10.1038/s41598-024-70139-6

Tsegaye, L., Bharti, R., 2022. The Impacts of LULC and Climate Change Scenarios on the Hydrology and Sediment Yield of Rib Watershed, Ethiopia. *Environmental Monitoring and Assessment*, 194(10): 717. https://doi.org/10.1007/s10661-022-10391-3

Wang, B., Fan, D. L., 2019. Research Progress of Deep Learning in Classification and Recognition of Remote Sensing Images. *Bulletin of Surveying and Mapping*, (2): 99－102, 136 (in Chinese with English abstract).

Wang, D. Z., Qiu, P. H., Fang, Y. M., 2015. Scale Effect of Li-Xiang Railway Construction Impact on Landscape Pattern and Its Ecological Risk. *Chinese Journal of Applied Ecology*, 26(8): 2493－503 (in Chinese with English abstract).

Wang, Q. Q., Yu, G. A., Li, Z. W., et al., 2025. Assessing the Ecohydrological Impact of Hydropower-Induced Flow Regulation on Fish Habitats in the Jinsha River. *Journal of Environmental Management*, 381: 125303. https://doi.org/10.1016/j.jenvman.2025.125303

Wen, Y. T., Cai, H., Han, D., 2024. Driving Factors Analysis of Spatial-Temporal Evolution of Vegetation Ecosystem in Rocky Desertification Restoration Area of Guizhou Province, China. *Environmental Science and Pollution Research*, 31(9): 13122－13140. https://doi.org/10.1007/s11356-024-31934-w

Xiao, Y., Guo, Y. H., Yin, G. D., et al., 2022. UAV Multispectral Image-Based Urban River Water Quality Monitoring Using Stacked Ensemble Machine Learning Algorithms—A Case Study of the Zhanghe River, China. *Remote Sensing*, 14(14): 3272. https://doi.org/10.3390/rs14143272

Xuan, B.X., Wei, X.Y., Mao, X.F., et al., 2025. Research on Ecosystem Services in the Xining-Haidong Metropolitan Area under Different Land Use Scenarios: Based on the GMOP-PLUS-InVEST Model. *Earth Science*, Online. https://link.cnki.net/urlid/42.1874.p.20250624.1606.002 (in Chinese with English abstract).

Yadav, P. K., Jha, P., Joy, M. S., et al., 2024. Ecosystem Health Assessment of East Kolkata Wetlands, India: Implications for Environmental Sustainability. *Journal of Environmental Management*, 366: 121809. https://doi.org/10.1016/j.jenvman.2024.121809

Zha, Y., Gao, J., Ni, S., 2003. Use of Normalized Difference Built-up Index in Automatically Mapping Urban Areas from TM Imagery. *International Journal of Remote Sensing*, 24(3): 583－594. https://doi. org/10.1080/01431160304987

Zhang, B., 2018. Remotely Sensed Big Data Era and Intelligent Information Extraction. *Geomatics and Information Science of Wuhan University*, 43(12): 1861－1871 (in Chinese with English abstract).

Zhang, Y. G., Cong, J., Lu, H., et al., 2015. Soil Bacterial Diversity Patterns and Drivers along an Elevational Gradient on Shennongjia Mountain, China. *Microbial Biotechnology*, 8(4): 739－746. https://doi. org/10.1111/1751-7915.12288

Zhang, Z. H., Zhang, G. X., Song, S. F., et al., 2020. Spatial Heterogeneity Influences of Environmental Control and Informal Regulation on Air Pollutant Emissions in China. *International Journal of Environmental Research and Public Health*, 17(13): 4857. https://doi. org/10.3390/ijerph17134857

Zhou, D., Song, W., 2021. Identifying Ecological Corridors and Networks in Mountainous Areas. *International Journal of Environmental Research and Public Health*, 18(9): 4797. https://doi.org/10.3390/ijerph18094797

中文参考文献

申艳军, 陈兴, 彭建兵, 等, 2024. 秦岭生态地质环境系统本底特征及研究体系初步构想. 地球科学, 49(6): 2103－2119.

王斌, 范冬林, 2019. 深度学习在遥感影像分类与识别中的研究进展综述. 测绘通报, (2): 99－102, 136.

王德智, 邱彭华, 方源敏, 2015. 丽香铁路建设对沿线景观格局影响的尺度效应及其生态风险. 应用生态学报,

26(8): 2493－2503.

宣炳旭, 魏晓燕, 毛旭锋, 等, 2025. 西宁-海东都市圈不同土地利用情景下生态系统服务模拟:基于 GMOP-PLUSInVEST 模型. 地球科学, 知网首发. https://link.cnki.net/urlid/42.1874.p.20250624.1606.002

张兵, 2018. 遥感大数据时代与智能信息提取. 武汉大学学报(信息科学版), 43(12): 1861－1871.

****

《地球科学》

2026年10月　第51卷　第10期　要目预告

基坑内支撑平面三阶段生成式设计方法 ……张　洁等
基于深度学习的滑坡灾害易发性评价及系统研发:以湖北省十堰市郧阳区为例 ……葛云峰等
融合物理机制的负样本优化策略与地震滑坡易发性评价 ……刘磊磊等
基于机器学习的重庆市万州区滑坡灾害降雨阈值与分区预警 ……蒋宏伟等
考虑自然地域分异的云南省滑坡易发性制图及其可解释性分析 ……吴文欢等
深埋隧洞穿越断层带瞬态渗流机制与渗透失稳风险评价 ……宋志忠等
土钉加固边坡智能优化设计方法 ……罗　琛等
小样本下岩体参数不确定性表征与围岩卸荷稳定性概率评价方法 ……刘国锋等
倾倒式危岩崩塌过程的微震原位试验研究 ……苏国韶等
基于伪随机对照与倾向得分匹配的切坡建房滑坡致灾效应定量研究 ……肖正辉等
中亚天山造山带高速远程滑坡动力学机理研究面临的重要科学问题 ……林棋文等