基于GEE与多源遥感数据融合的煤火灾害智能动态监测方法

张　远[1],崔　柳[1],杨　慧[1,2,3],冯　健[4],沈冰舰[4],王　勇[3],马国强[4]
(1. 中国矿业大学 资源与地球科学学院,江苏 徐州　221116;2. 中国矿业大学 煤层气资源与成藏过程教育部重点实验室,江苏 徐州　221116;3. 乌鲁木齐气象卫星地面站,新疆 乌鲁木齐　830000;4. 新疆维吾尔自治区地质局煤田地质中心,新疆 乌鲁木齐　830000)

摘要: 煤火灾害是制约我国煤炭资源安全与生态环境保护的重大地质灾害之一. 针对传统遥感煤火监测方法在空间分辨率与异常提取精度方面的不足,本文以新疆准东老君庙煤田为研究区,融合多源遥感数据,构建了基于谷歌地球引擎(Google Earth Engine,GEE)平台的煤火智能监测框架. 首先,基于Sentinel-2高分辨率多光谱特征与Landsat-8热红外数据,构建包含光谱波段与指数的多维输入特征集,采用改进的U-Net网络实现地表温度的10 m空间降尺度重建,提升了热异常信息的空间表达精度;其次,引入自编码器无监督异常检测方法,在无需人工标注的情况下自动识别煤火区域,实现煤火边界的准确提取与分布动态变化追踪;最后,结合多时相煤火区识别结果,提出煤火热异常指数(CFTA),量化分析并揭示2016—2025年间煤火活动的时空演化与治理成效. 结果表明:所提出的智能监测框架可有效捕捉煤火发展与治理过程中的动态变化,具有高空间分辨率与高监测灵敏度的优势,为煤火灾害的精准监测与防控提供了可靠的方法支撑.

关键词: 煤火监测;谷歌地球引擎;深度学习;地表温度;降尺度
中图分类号: P 237　　**文献标志码:** A　　**文章编号:** 1000-1964(2026)02-0406-13

An intelligent and dynamic monitoring method for coal fire hazards based on GEE and multi-source remote sensing data fusion

ZHANG Yuan[1], CUI Liu[1], YANG Hui[1,2,3], FENG Jian[4], SHEN Bingjian[4], WANG Yong[3], MA Guoqiang[4]
(1. School of Resources and Geosciences, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China; 2. Key Laboratory of Coalbed Methane Resources & Reservoir Formation Process, Ministry of Education, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China; 3. Urumqi Meteorological Satellite Ground Station, Urumqi, Xinjiang 830000, China; 4. Coal Geology Center, Xinjiang Bureau of Geology and Mineral Resources, Urumqi, Xinjiang 830000, China)

Abstract: Coal fires are a major geological hazard that severely constrain coal resource security and ecological environmental protection in China. To address the limitations of traditional remote sens-

收稿日期: 2025-10-15　　**修回日期:** 2025-12-29　　**DOI:** 10.13247/j.cnki.jcumt.20250442
基金项目: 国家自然科学基金面上项目(42571545);第三次新疆综合科学考察项目(2022xjkk1006);新疆维吾尔自治区重点研发任务专项(2022B01012-1)
第一作者: 张　远(1996—),男,安徽省宿州市人,理学博士. E-mail: zhangyuan_cumt@cumt.edu.cn
通信作者: 杨　慧(1983—),女,江苏省泰州市人,教授,博士生导师. Email: yanghui@cumt.edu.cn
引用格式: 张　远,崔　柳,杨　慧,等. 基于GEE与多源遥感数据融合的煤火灾害智能动态监测方法[J]. 中国矿业大学学报,2026,55(2):406-418.
ZHANG Yuan, CUI Liu, YANG Hui, et al. An intelligent and dynamic monitoring method for coal fire hazards based on GEE and multi-source remote sensing data fusion[J]. Journal of China University of Mining & Technology, 2026, 55(2): 406-418.

ing methods for coal fire monitoring, specifically in spatial resolution and anomaly extraction accuracy, this study takes the Laojunmiao coalfield in the eastern Junggar Basin of Xinjiang as the research area and develops an intelligent coal fire monitoring framework based on the Google Earth Engine (GEE) platform by integrating multi-source remote sensing data. First, high-resolution multispectral features from Sentinel-2 and thermal infrared data from Landsat-8 are fused to construct a multi-dimensional input feature set composed of spectral bands and indices. An improved U-Net network is then employed to achieve 10 m spatial downscaling reconstruction of land surface temperature (LST), significantly enhancing the spatial accuracy of thermal anomaly information. Second, an unsupervised anomaly detection method based on autoencoders is introduced to automatically identify coal fire regions without the need for manual labeling, enabling precise boundary extraction and dynamic tracking of distribution changes. Finally, by combining multi-temporal coal fire identification results, a coal fire thermal anomaly index (CFTA) is proposed to quantitatively analyze the spatiotemporal evolution of coal fire activities and their mitigation effects from 2016 to 2025. The results demonstrate that the proposed intelligent monitoring framework can effectively capture the dynamic changes during coal fire development and remediation processes, offering high spatial resolution and sensitivity. This provides a reliable technical pathway for accurate monitoring and prevention of coal fire hazards.

Key words: coal fire monitoring; Google Earth Engine; deep learning; land surface temperature; downscaling

煤火灾害是由地表或地下煤层的长期自燃所引发的地质灾害[1]，不仅严重威胁矿区安全生产，还造成煤炭资源的大量浪费和生态环境的持续退化. 我国煤火灾害问题严峻，主要分布于新疆、内蒙古、宁夏等地区，已成为国家能源安全、矿区绿色转型与“双碳”战略目标实现的关键制约因素[2-3]. 因此，研究高效精准的煤火灾害智能动态监测方法，对煤炭资源保护、生态修复与可持续发展具有重大现实意义[4-5].

遥感技术凭借其大范围覆盖、非接触式观测等优势，已成为煤火大范围、动态监测的重要技术手段[6-7]. 其中，热红外遥感通过捕捉燃烧煤层与周围环境之间的热辐射差异，为煤火识别提供了最直接的观测依据[8-9]. 早期研究主要基于Landsat TM/ETM+等卫星平台和无人机的单一热红外波段数据，采用目视解译或简单的温度阈值法初步圈定火区范围[10]. 随着遥感平台和传感器的不断发展，监测手段开始向多源数据融合和定量反演转变，MODIS、ASTER 和 Sentinel-2/3 等数据源被逐步引入[11-13]，研究方法也从简单的温度阈值法，演进到融合温度、植被、地形、沉降等多特征的综合识别体系[14-16].

尽管监测技术不断进步，但现有煤火遥感监测仍普遍面临热红外数据空间分辨率不足的瓶颈[17]. 当前广泛使用的热红外数据源，如Landsat系列热红外波段分辨率约为 100 m，而MODIS数据更是达到1 000 m像元尺度，无法精确识别小规模火源，也难以捕捉煤火的快速动态演变[18]. 这一局限性导致在复杂地形和异质性高的区域，混合像元效应显著，火区边界提取不精确，小火点漏检率高. 虽然基于随机森林或物理模型的等地表温度数据的降尺度研究取得一定进展[19-20]，但其精度和稳定性仍需提升.

在煤火识别算法方面，传统算法主要依赖于阈值分割、滑动窗口、时序分解等规则驱动方法[21-23]. 上述方法虽然在一定程度上能够提取热异常特征，但其往往依赖人工经验设定阈值或规则，且在复杂地形背景或多样地表覆盖条件下泛化能力有限. 此外，当前算法性能高度依赖于数据质量与先验知识，难以适应煤火分布的高度不均匀性与非线性特征[24]. 随着人工智能技术的发展，遥感信息的智能提取进入了数据驱动的新阶段[25-26]. 近年来，基于机器学习的煤火识别方法逐渐兴起，通过构建面向目标的多维特征表达模型，有效提升了识别的精度与鲁棒性[27-28]. 然而，当前大多数机器学习、深度学习方法仍属于典型的监督学习范式，严重依赖大量高质量的标注样本. 而在煤火监测研究中，受限于野外调查难度大、标注

成本高等因素，构建大规模、高质量训练集面临诸多现实挑战；同时，由于煤火区域在遥感影像中呈现出空间分布不均、面积小、边界模糊等特性，正负样本之间比例严重失衡，进一步加剧了模型训练的偏倚风险与过拟合问题．在此背景下，无监督或弱监督的深度学习方法为煤火智能识别提供了新的可能路径．例如，自编码器（AutoEncoder，AE）能够在缺乏标注的情况下学习正常地表的特征分布，通过重建误差识别异常区域[29]；而对比学习（Contrastive Learning）则通过构建正负样本对，增强模型对特征差异的感知能力，提升小样本场景下的识别性能[30]．该类方法在异常提取、无标注建模方面展现出良好潜力，可为复杂背景下的煤火自动检测提供新的研究方向．

在遥感数据获取与处理平台方面，谷歌地球引擎（Google Earth Engine，GEE）平台作为全球领先的地球科学云计算平台，集成了包括 Landsat、Sentinel、MODIS 在内的多源遥感数据，为开展大范围、长时序、高频次的矿区动态监测提供了支持[31-32]．然而，目前 GEE 在煤火监测中的应用仍相对有限，多停留在简单的时序温度分析层面，深度学习模型与 GEE 平台之间的高效集成与协同创新仍显不足．如何充分利用 GEE 的多源数据优势并结合深度学习模型[33-34]，实现煤火监测的智能化、自动化，仍是当前亟待解决的关键问题．

综上所述，现有煤火遥感监测研究在热红外影像空间分辨率、识别算法智能化程度等方面仍存在明显不足．针对上述研究现状与瓶颈问题，本文以新疆准东老君庙煤田为研究区，构建了一个融合 GEE 遥感数据平台、基于深度学习的地表温度降尺度方法与煤火智能识别技术于一体的遥感监测框架．研究首先利用 U-Net 模型实现热红外数据的空间增强，提升地表温度数据的空间分辨率；在此基础上，进一步结合基于自编码模型的异常检测方法，实现煤火区域的高精度自动识别；最终，开展煤火的时空演变分析，以期为煤火灾害的科学评估、动态监测与治理成效评价提供可靠的方法支撑与理论参考．

1 研究区概况

老君庙矿区位于新疆昌吉回族自治州木垒哈萨克自治县境内，地处木垒县城以北至东北方向约 50～90 km 之间的冲积戈壁平原荒漠地带[35]．矿区中心点地理坐标为北纬 44°25′55″，东经 90°29′11″（图 1）．该区是我国目前已探明资源量最大的整装煤田——准东煤田的重要组成部分．老君庙矿区规划总面积约 250.4 km^2，煤炭资源储量极为丰富，具有赋存稳定、埋藏浅、厚度大和煤质优良等特征，是准东煤田产能建设的主要露天开采区域之一．研究区地貌类型为典型的残丘状剥蚀平原，地势总体呈南高北低趋势，地形开阔且平坦，坡度多介于 1°～10°之间．气候为典型的大陆性中温带干旱气候，特征为年温差与昼夜温差显著，气候干燥，降水稀少．夏季最高气温可达 43 ℃，冬季最低气温降至－30 ℃以下．区域年均降水量低，蒸发强烈，干旱程度明显，每年 11 月至次年 3 月为封冻期．

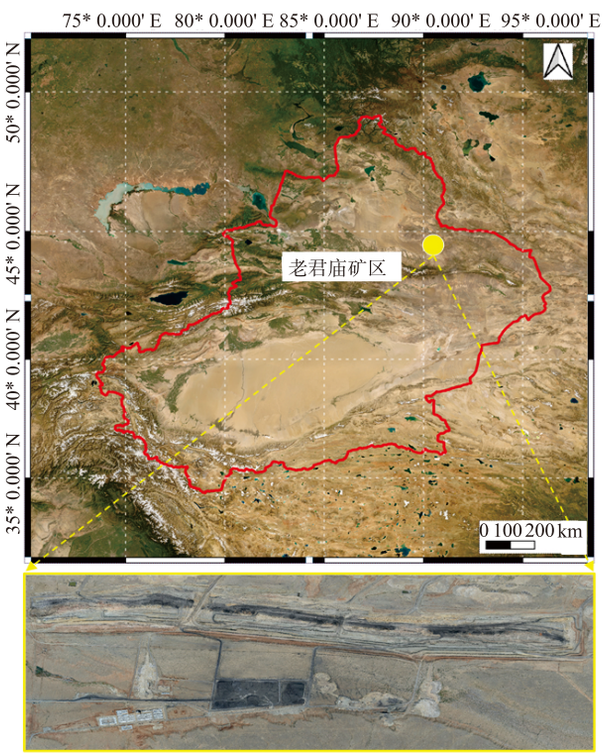


图 1 新疆准东老君庙矿区

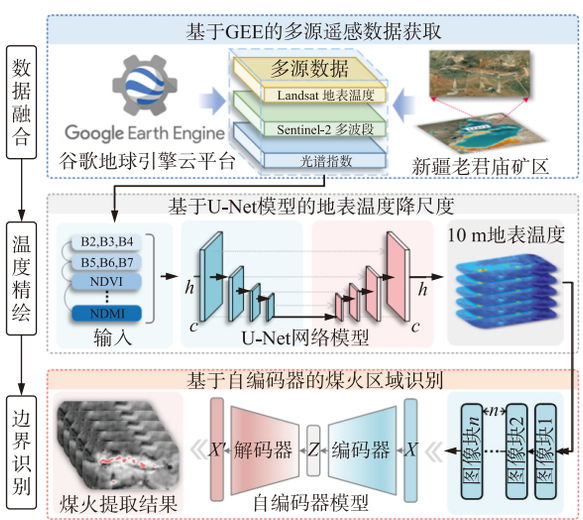
Fig. 1 Laojunmiao mining area, Zhundong, Xinjiang

老君庙矿区煤层普遍埋藏较浅，倾角变化较大，断层与裂隙较为发育，构成煤火自燃的主控因素．水文地质条件表现为地下水贫乏，对深部煤火的窒息作用有限．煤火集中分布于构造复杂的煤层露头及破碎带，其蔓延规模受裂隙系统与巨厚煤层共同控制．老君庙煤田煤火灾害历史悠久，部分火区已持续燃烧 50 余年，形成了多处规模较大、危害严重的火区．煤火主要分布于矿区西部与中部地带，集中出现在煤层露头带、采空区、断层破碎带及风化裂隙发育区等高风险区域．持续燃烧的煤火不仅造成大量煤炭资源流失，还诱发地表塌陷、土壤退化与荒漠化加剧，并释放有害气体和

烟尘，严重影响区域生态环境与周边居民健康，亟需开展科学监测与有效治理.

2　数据与方法

为系统揭示煤火灾害的时空演化过程并实现高精度动态监测，本文构建了融合多源遥感数据、深度学习建模与无监督异常检测的智能遥感监测方法框架. 该框架依托GEE平台实现数据获取与处理，采用改进U-Net模型对热红外地表温度数据进行10 m降尺度重建，并引入自编码器方法在无需人工标注的前提下完成煤火区域识别. 整体技术流程如图2所示，主要包括3个步骤：1)多源遥感数据获取与预处理；2)地表温度超分辨率重建；3)煤火区域边界智能识别.



注：B2～B7为哨兵-2多光谱波段；NDVI为归一化植被指数；NDMI为归一化水分指数；h，c分别为特征图的空间尺寸和通道数；X和X'分别为输入和输出的图像块；Z为潜变量.

图2　研究总体技术路线

Fig. 2　Overall technical roadmap of the study

2.1　数据获取与预处理

依托GEE云平台构建多源遥感数据协同处理框架，主要获取的数据源包括Landsat-8地表温度（Land Surface Temperature，LST）产品和Sentinel-2多光谱影像. Landsat-8卫星搭载的热红外传感器（Thermal Infrared Sensor，TIRS）提供2个热红外波段，原始空间分辨率为100 m，LST产品经重采样处理至30 m网格，重访周期为16 d. Sentinel-2卫星的多光谱成像仪（Multi-Spectral Instrument，MSI）包含13个光谱波段，其中蓝光（B2）、绿光（B3）、红光（B4）和宽近红外（B8）波段的分辨率为10 m；红边波段（B5，B6，B7）、窄近红外（B8A）和短波红外波段（B11，B12）的分辨率为20 m，重访周期为5 d. Sentinel-2的高分辨率多光谱数据为地表温度降尺度重建提供了丰富的地表反射特征信息，从而有效弥补Landsat-8热红外数据的空间局限性.

考虑到植被物候变化、土壤水分波动以及季节性太阳辐射差异可能干扰煤火热异常信号，本研究将数据获取时间窗口严格限定为每年1～2月（2016—2025年）. 这一时段对应研究区的封冻期，植被处于休眠状态，地表干燥，大气透过率较高，环境背景相对稳定，有利于突出煤火燃烧引发的热异常特征. 同时，为应对光学遥感影像常见的云污染问题，设定影像云覆盖率阈值不超过20%，并利用GEE平台内置的质量评估（Quality Assessment，QA）波段与Fmask云检测算法自动筛选高质量晴空影像. 通过上述时空约束与质量控制策略，最终获取的符合条件卫星影像数量如图3所示.

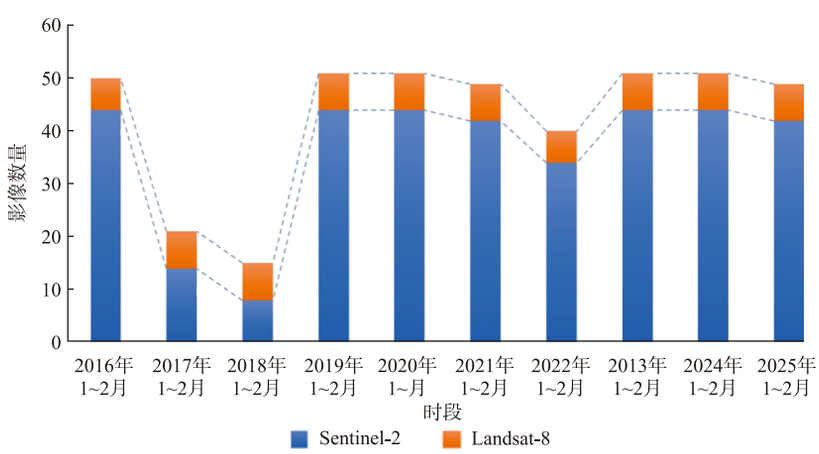


图3　研究使用的卫星影像数量

Fig. 3　Number of satellite images used in the study

为充分挖掘Sentinel-2在空间信息与地表物理属性表达方面的优势，构建了包含波段特征和指数特征的综合数据集，作为后续地表温度降尺度重建的输入．该数据集由以下两部分构成：1)光谱波段特征，包括原始10 m分辨率的蓝光、绿光、红光与近红外波段，以及通过双三次插值上采样至10 m分辨率的红边、窄近红外与短波红外波段．这些波段全面捕捉了地表对不同波长电磁辐射的反射特性，是温度降尺度映射的基础信息源．2)光谱指数特征，结合遥感波段计算得到4种光谱指数，包括归一化植被指数(NDVI)、归一化含水指数(NDMI)、归一化建筑指数(NDBI)和归一化燃烧指数(NBR)，分别反映地表植被、水分、人为建设和燃烧活动等信息，为热异常识别提供先验环境特征支撑．各指数的计算公式、物理含义及应用目的详见表1.

表1 研究采用的光谱指数

Table 1 Spectral indices used in the study

指数	计算公式	含义及作用
NDVI	$I_{\mathrm{NDV}}=\dfrac{R_{\mathrm{NI}}-R}{R_{\mathrm{NI}}+R}$	归一化植被指数，反映植被覆盖度与生物量．
NDMI	$I_{\mathrm{NDM}}=\dfrac{R_{\mathrm{NI}}-R_{\mathrm{SWI,1}}}{R_{\mathrm{NI}}+R_{\mathrm{SWI,1}}}$	归一化差值含水指数，对水分含量敏感．
NDBI	$I_{\mathrm{NDB}}=\dfrac{R_{\mathrm{SWI}}-R_{\mathrm{NI}}}{R_{\mathrm{SWI}}+R_{\mathrm{NI}}}$	归一化建筑指数，辅助区分人为热源与煤火热异常．
NBR	$R_{\mathrm{NB}}=\dfrac{R_{\mathrm{NI}}-R_{\mathrm{SWI,2}}}{R_{\mathrm{NI}}+R_{\mathrm{SWI,2}}}$	归一化燃烧指数，增强对热异常的敏感性

注：R，R_{NI}，$R_{\mathrm{SWI,1}}$，$R_{\mathrm{SWI,2}}$分别为红光、近红外、短波红外1、短波红外2波段的地表反射率．

在数据预处理阶段，所有光谱波段经min-max归一化处理至[0，1]区间，光谱指数则处理至[−1，1]范围，以统一数值尺度；对于数据中的缺失值，采用邻近有效像元中值填充策略，以确保输入数据的完整性与数值稳定性．同时，将30 m分辨率的Landsat 8地表温度产品通过双三次样条插值上采样至10 m，作为模型的初始温度估计．该初始温度场与Sentinel-2的10 m光谱波段特征在通道维度进行拼接，共同构成模型的输入张量．

2.2 基于U-Net的地表温度降尺度模型

为突破热红外遥感地表温度产品空间分辨率较低导致的细节表达不足问题，本文在经典U-Net编码器-解码器框架基础上构建改进型降尺度网络，实现将Landsat 8的30 m LST增强至10 m分辨率．模型采用对称的下采样/上采样结构以提取多尺度空间特征，并进一步引入通道注意力与空间注意力机制，以提升煤火热点区及边缘过渡带的结构恢复能力．同时，为提高训练稳定性与收敛效率，本文采用残差学习策略，即网络不直接回归高分辨率LST，而是学习初始上采样温度场与高分辨率参考LST之间的残差项．具体细节如下：

在网络结构方面，该U-Net模型架构包含编码器、解码器与跳跃连接3个核心部分．首先，通过一个由3×3卷积、批量归一化与ReLU激活组成的特征提取模块，得到64通道基础特征图．随后嵌入通道注意力模块，通过全局池化与1×1卷积生成通道权重，强化与LST相关性高的光谱通道．编码器由两级下采样层构成，每级包含2×2最大池化与双卷积块，通道数从64逐步扩展至256，以提取多尺度特征．解码器对应采用两级上采样层，通过最近邻插值恢复分辨率，并结合跳跃连接融合编码器传递的细节特征，避免信息丢失．在解码器输出后引入空间注意力模块，利用7×7卷积生成空间权重图，突出煤火高温区及显著温度梯度．最终，将空间注意力输出与初始上采样LST在通道维度拼接，通过最终的3×3卷积层回归LST残差，得到最终预测结果：

$$T_{\mathrm{LS,p}}=T_{\mathrm{LS,i}}+\Delta T_{\mathrm{LS}}\ , \tag{1}$$

式中：$T_{\mathrm{LS,p}}$为最终降尺度结果；$T_{\mathrm{LS,i}}$为初始温度场；ΔT_{LS}为网络学习到的残差项．

在损失函数方面，为兼顾预测精度与空间结构保持性，本文构建了由平均绝对误差(MAE)与梯度保持损失共同构成的复合损失函数．前者用于约束预测值与真实LST之间的整体偏差，后者利用Sobel算子计算空间梯度，以保持温度场边缘和高温区的清晰性，防止模型过度平滑造成热点模糊．其中绝对误差损失公式为

$$\mathcal{L}_1=\frac{1}{N}\sum_{j=1}^{N}\left|T_{\mathrm{LS,p}}^{j}-T_{\mathrm{LS,i}}^{j}\right|, \tag{2}$$

式中：$\mathcal{L}_1$为像元级$L1$损失(即平均绝对误差)；上标j表示像元序号；N为参与计算的像元数量．

梯度保持损失$\mathcal{L}_g$公式为

$$\mathcal{L}_{\mathrm{g}}=\frac{1}{N}\sum_{j=1}^{N}\left|\nabla T_{\mathrm{LS,p}}^{j}-\nabla T_{\mathrm{LS,i}}^{j}\right|, \tag{3}$$

式中 ∇为Sobel算子计算的梯度幅值．

总损失函数为

$$\mathcal{L}=\mathcal{L}_1+\lambda\mathcal{L}_{\mathrm{g}}\ , \tag{4}$$

式中 λ为权重系数，根据测试经验将其设定为0.5.

模型训练过程中，使用256×256像元大小的图像块作为输入样本，采用随机裁剪、旋转和翻转进行数据增强；优化器为AdamW，初始学习率为0.001，训练过程中采用余弦退火与热重启策略调整学习率，并引入早停策略以防止过拟合．模型训练轮数为100，批次大小设为8．

2.3　基于自编码器的煤火区域识别模型

在实现地表温度高分辨率重建的基础上，进一步设计基于自编码器的无监督煤火区域识别方法，旨在不依赖人工标注样本的条件下，自动检测研究区内的异常高温区域．该方法基于以下基本假设：研究区正常地表温度场具有一定的空间连续性与规律性，而由煤火引起的热异常具有突变性与局部异质性．自编码器通过学习大量正常温度块的重构模式，可在输入包含异常区域时表现出较大的重建误差，从而实现异常检测．具体技术流程如下：

1）数据预处理与分块．以降尺度生成的10 m分辨率地表温度数据作为输入，首先依据地理元数据剔除云覆盖及无效观测区域．随后，对有效温度像元进行z-score标准化处理，消除季节性与区域性背景温度波动的影响．为提取局部温度场的空间结构特征，将标准化后的温度场按8×8像元窗口（对应80 m×80 m空间范围）进行滑动分块，步长设为2像元以增强样本覆盖度．剔除包含无效值的图像块后，将每一温度块展平为64维向量，构建自监督训练样本集．

2）自编码器构建与训练．自编码器网络采用对称的全连接结构，编码器通过3层映射逐步压缩输入数据，提取温度场的低维本质特征；解码器通过对称结构实现温度场的逐层重建．所有隐藏层均采用ReLU激活函数并引入批量归一化操作，输出层使用Tanh激活函数以匹配标准化后温度值的分布范围．模型以最小化输入与输出间的均方误差为优化目标，采用Adam优化器进行训练．

3）异常分数计算与后处理．将每个温度块输入训练好的自编码器，计算其重建均方误差，并将该误差值赋给块内所有有效像元，生成与输入温度场空间一致的原始异常分数图．为抑制分块处理引入的边界效应与随机噪声，对异常分数图执行标准差$\sigma=1$的高斯空间滤波．在此基础上，基于热异常在空间上属于小概率事件的统计假设，以所有正异常分数像元的第99百分位数作为自适应阈值，生成二元掩膜，从而实现煤火区域边界的自动识别．

3　结果与分析

在前述方法框架的支撑下，本文基于2016—2025年准东老君庙煤田多时相遥感数据，开展了煤火灾害的高分辨率动态监测与演化趋势分析．通过地表温度的降尺度重建、煤火区域识别、无人机热红外影像验证以及热异常指标的构建与量化评估，以揭示该区域煤火灾害的空间格局与时间演变．

3.1　地表温度降尺度结果

图4展示了基于U-Net模型对2016—2025年1～2月地表温度进行降尺度处理后的结果．整体来看，研究区温度场呈现出明显的年度变化规律，且空间分布具有较强的异质性，尤其以西部和东部2个区域为主的高温异常区尤为突出．

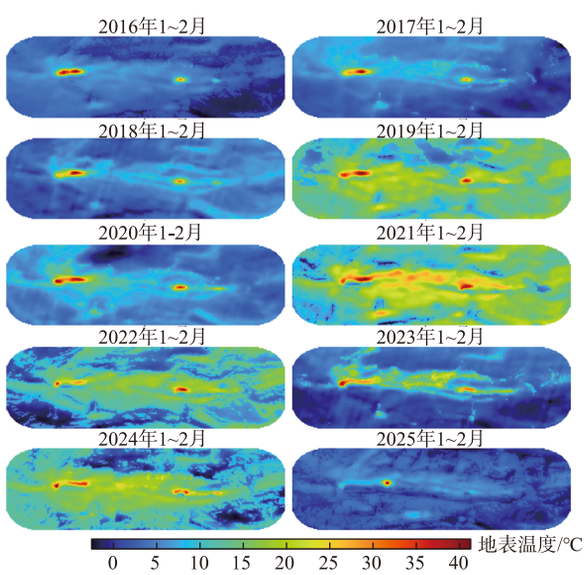


图4　2016—2025年的10 m地表温度降尺度结果

Fig. 4　Downscaling results of 10 m LST from 2016 to 2025

如图4所示，在2016—2018年，西部和东部的高温斑块分布较为稳定，呈现孤岛式局部异常特征，与区域内已知的煤层露头带和采空区高度重叠，表明煤火活动仍处于相对早期阶段；2019年后，受煤矿开采活动增强的影响，中部温度略有升高，局部斑块开始出现连接趋势；2020年，LST影像显著变化，温度异常点迅速增加，多个高温热点开始形成连续热带，呈现出多点爆发的特征，整体温度峰值显著超过前几年水平．特别是在研究区中部形成一条明显的高温条带，显示火势在沿煤层走向方向快速蔓延；2021年为温度异常峰值年，

不仅高温区面积最大，背景温度也显著升高，红橙色高温像素广泛分布，表明煤火对区域热环境造成累积增温效应；2022 年起，LST 图像出现转折，高温斑块由连续带状转为破碎状；2023 年，研究区地表温度整体呈回落趋势，连片性明显下降，表明煤火治理初见成效，但高温区域范围在 2024 年出现短期扩大；至 2025 年，高温区域显著收缩，仅残留零星火点，研究区背景温度趋于稳定，表明煤火带来的热累积效应已大幅消退，治理措施取得显著成效．此外在研究区东南部首次出现一个小规模热异常点，现场实地勘查为复燃现象．

3.2 与无人机热红外影像的对比验证

为评估基于卫星遥感数据的煤火识别结果的准确性和应用可行性，本研究以 2023 年在研究区采集的无人机热红外影像作为地面真实参考，对本文提出的 10 m 降尺度地表温度数据与无人机实测温度场进行定量对比分析．航摄平台为大疆经纬 M300 RTK 旋翼无人机，搭载 H20T 热红外相机，具备－40～550 ℃的测温范围和±1.5% 的测温精度，能够提供亚米级空间分辨率的热红外辐射信息．如图 5 所示，上方图 5a 为 2024 年基于 Landsat 8 原始 LST 数据与 Sentinel-2 多光谱数据融合后，经 U-Net 模型降尺度处理的 10 m 分辨率地表温度分布图（2024 年 1～2 月份数据）；下方图 5b 为无人机热红外正射影像拼接结果（2023 年夏季成像）．

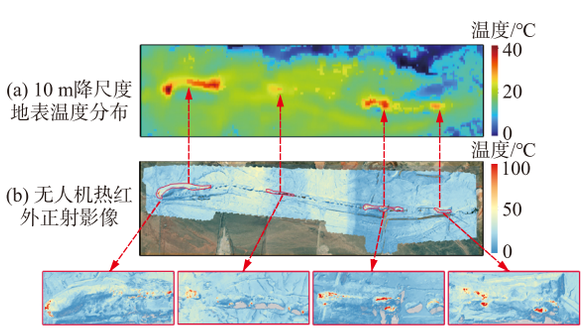


图 5 降尺度 LST 与无人机热红外影像对比

Fig. 5 Comparison between downscaled LST and UAV thermal infrared imagery

从整体空间格局来看，10 m 降尺度地表温度数据与无人机热红外影像在多个关键煤火区域表现出高度一致性，热点区位置能够准确吻合，高温区域的形态也较为相似．图 5 标注的 4 个典型高温异常点，在两类数据中均显示出明显的局地温度峰值，进一步验证了卫星遥感识别结果的空间准确性．在空间细节层面，无人机热红外图像中的火区边界轮廓清晰、热点分布集中，表现出更高的空间细节分辨能力，这一优势主要源于其近地面成像视角和亚米级空间分辨率．本研究提出的 U-Net 降尺度方法虽然受限于卫星传感器的固有分辨率，但模型重建出的热点斑块与无人机图像中的高温异常区域高度重叠，实现了良好的空间拟合．这表明，该降尺度方法能够有效重构地表温度的空间细节，从而显著提升煤火区域识别的精度．

尽管整体表现良好，局部区域仍存在一定偏差．一方面，由于无人机与卫星成像在时间和传感器校准上存在差异，导致煤火区域在热异常强度表征上出现不一致；另一方面，在地形起伏强烈的裸露阳坡或岩石背景区，高反照率和近似温度梯度的干扰可能导致局部偏差．这些问题在未来研究中可通过引入地形校正和多时相数据融合进一步改善．

通过与无人机高分辨率热红外影像的对比验证，本研究提出的降尺度 LST 重建方法展现出优异的空间表达能力和实际应用潜力，能够在缺乏实地数据支持的条件下，实现对煤火高温异常区域的高精度定位，为大范围、长时序煤火监测提供了可靠的技术支撑．

3.3 煤火区域识别结果

图 6 为基于自编码器模型识别的煤火区域图，利用重建误差对高温异常中的潜在煤火区域进行精准检测，其中红色区域表示模型识别出的煤火区域．图 6 结果表明，在 2016 年，模型识别出 3 个主要火区，呈不规则斑块状分布，边界清晰，位置与热异常高度吻合．2017—2018 年，火区数量及面积小幅增加，新增火点多位于原有火区外围，呈“卫星状”分布，体现出煤火沿地下煤层缓慢扩张的趋势．2019—2021 年为典型的连片爆发阶段，多个原本孤立的火区开始相互融合，形成连续的高温连片区域，西部与东部火区之间的过渡地带出现了多处新火点，区域整体活跃度达到峰值，表现出煤火灾害快速蔓延态势．2022 年后识别结果出现明显变化，火区面积显著减少．图像中可见多个原本连片火区开始破碎化，煤火斑块边缘出现消退趋势，显示多个治理措施（如注浆降温、地表封堵等）在关键区域产生了明显效果．2023—2024 年，治理成效持续显现，识别出的火区面积进一步收缩，分布趋于零散化．至 2025 年，研究区内仅在东南部识别出一个新兴小规模火点，其他区域火区几乎完全清除．

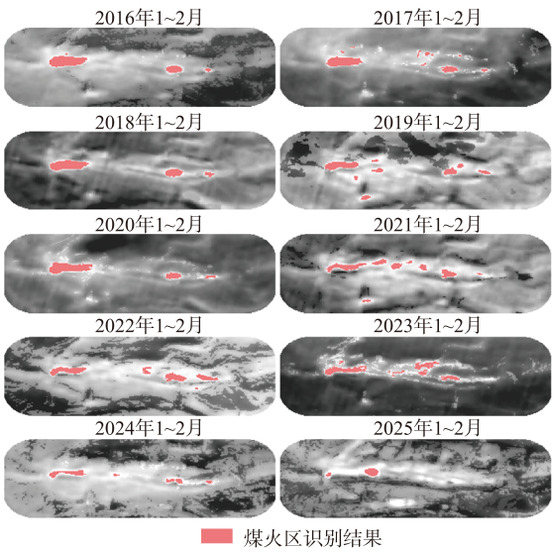


图 6　2016—2025 年煤火提取结果

Fig. 6　2016—2025 coal fire extraction results

3.4　煤火区时序动态分析

为进一步刻画煤火灾害的演化过程与治理成效，本研究在多时相提取的煤火区掩膜基础上，进一步提出了煤火区热异常指数（Coal Fire Thermal Anomaly index，CFTA），用于综合评价不同年份煤火热异常的强度与空间爆发程度．该指数综合考虑了煤火区域与研究区的温度差异，并通过归一化标准差和面积占比进行尺度统一与调节，其定义如下：

$$I_{\mathrm{CFTA}}=\frac{\left(\overline{T_{\mathrm{LS,\,fire}}}-\overline{T_{\mathrm{LS,\,total}}}\right)}{\sigma}\times\frac{S_{\mathrm{fire}}}{S_{\mathrm{total}}},\qquad(5)$$

式中：I_{CFTA} 为煤火区热异常指数；$\overline{T_{\mathrm{LS,\,fire}}}$ 为煤火区域的平均地表温度；$\overline{T_{\mathrm{LS,\,total}}}$ 为研究区全域的平均地表温度；σ 为研究区地表温度的标准差；S_{fire} 为煤火区面积；S_{total} 为研究区总面积．CFTA 指数通过标准差归一化温度差值，有效增强了不同年份、不同热背景下煤火热异常强度的可比性，同时结合空间覆盖比例体现其爆发程度，因此更能全面刻画煤火灾害的综合风险水平．

图 7 展示了 2016—2025 年间煤火区域面积（蓝色柱状图）与煤火热异常指数（红色折线图）的年际变化趋势．结果表明，2016—2021 年期间，煤火区面积基本维持在 0.4～0.5 km^2之间，CFTA 值也稳定在 7.5%～9.0% 的较高区间，表明该阶段煤火活动强烈，空间覆盖广泛，地表热异常显著．自 2022 年起，随着煤火治理工程的逐步推进，煤火区面积与 CFTA 指数均呈现明显下降趋势，煤火活跃度和热异常强度开始得到有效抑制．尤其在 2024 年，火区治理工作全面铺开，治理成效显著，煤火区面积较前期峰值大幅缩减，CFTA 值也降至显著低位．至 2025 年，煤火区域面积与热异常强度双双降至最低水平，反映出煤火灾害在治理措施干预下持续缓解，整体风险呈现逐年减弱的趋势．

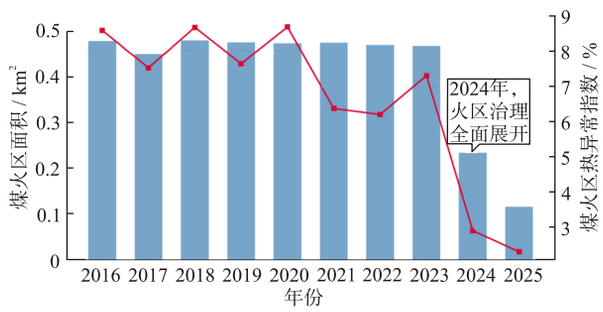


图 7　2016—2025 年煤火区面积和热异常指数的变化

Fig. 7　Changes in coal fire area and thermal CFTA index from 2016 to 2025

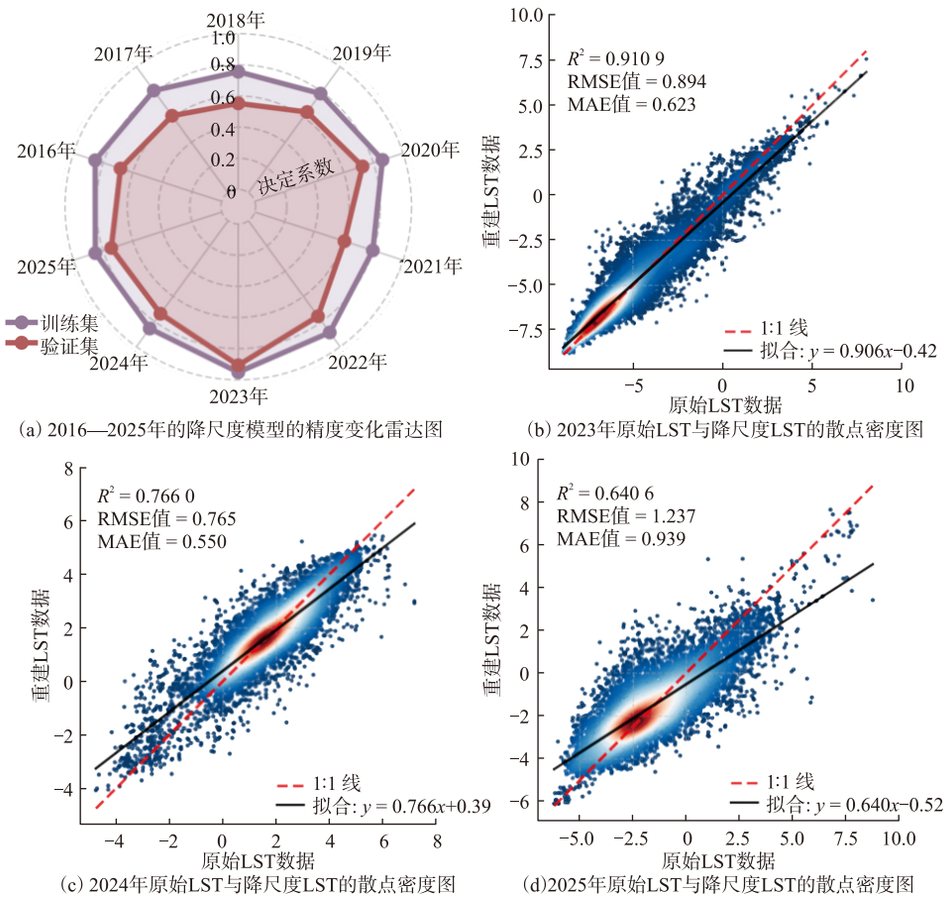
综上，CFTA 指数在量化煤火灾害长期变化趋势、评估热异常显著性，以及动态对比不同年份治理成效方面，具有较强的敏感性与区分度，可推广应用于进行煤火动态态势监测判据．

4　讨 论

4.1　U-Net降尺度模型的优势分析

为定量评估本文所构建的 U-Net 降尺度模型性能，本研究采用随机抽样方式将样本按 7∶3 划分为训练集与验证集，并以“逐年建模-逐年检验”的方式，在像元尺度上计算决定系数（R^2）、均方根误差（RMSE）与平均绝对误差（MAE），以综合刻画模型的拟合能力与泛化稳定性．

如图 8a 所示，2016—2025 年间验证集 R^2 整体保持在较高水平，多数年份高于 0.6，部分年份接近或超过 0.8，且年份间波动较小，说明模型在不同年份均具备良好的泛化能力，未出现过拟合现象．进一步选取 2023—2025 年作为典型年份，绘制原始 LST 与重建 LST 的像元对比散点密度图（图 8b～8d）．结果显示，散点沿 1∶1 线高度聚集，高密度区域集中分布于对角线附近，表明降尺度结果与原始 LST 产品在数值幅度上具有较好的一致性．值得注意的是，线性拟合斜率普遍略小于 1，这反映降尺度过程中对极端高值的一定平滑效应．不同年份之间的 R^2 存在一定差异，反映了不同年份遥感数据质量与实际环境条件的动态变化，属于统计层面的正常现象，而非模型性能的实质性改变．从 RMSE 和 MAE 值等绝对误差指标来看，模型在各年度均保持了较为稳定的重建精度，表明所提出方法在多时相条件下具有良好的稳健性．



(a) 2016—2025年的降尺度模型的精度变化雷达图
(b) 2023年原始LST与降尺度LST的散点密度图
(c) 2024年原始LST与降尺度LST的散点密度图
(d)2025年原始LST与降尺度LST的散点密度图

图 8 U-Net降尺度模型精度评估

Fig. 8 Accuracy assessment of the U-Net downscaling model

为进一步检验所提U-Net降尺度模型的相对优势，本研究将其与其他4种具有代表性传统机器学习模型进行了横向对比，即多元线性回归、随机森林、极端梯度提升(XGBoost)、多层感知机模型. 为确保对比的公平性与结果的可比性，所有模型均采用相同的数据划分方案. 结果如图9所示，2020—2025年间各模型的精度对比结果表明，U-Net在多数年份中均表现出最优的综合性能，其R^2值基本保持最高，同时MAE与RMSE值在各年份普遍低于其他方法. 这说明U-Net不仅在拟合精度上具有优势，且在不同年份数据分布变化下仍能保持较好的误差控制能力与重建稳定性. 相比之下，其他对比方法的表现存在一定波动：XGBoost在部分年份的精度仅次于U-Net，但其误差指标跨年波动较大；随机森林与多层感知机在某些年份可达较好精度，但整体稳健性不及U-Net；多元线性回归模型的各项指标均显著落后.

在多指标对比的基础上，进一步引入泰勒图(图10)对各模型进行综合评估. 结果表明，2021—2024年各年份中，U-Net模型的点位均最接近参考点(原始LST)：其标准差与参考值匹配度最高，相关系数处于最高水平，并整体落在较小RMS误差等值线附近. 这说明U-Net不仅能够较好保持温度场的整体振幅，同时能够更准确地再现空间分布格局与梯度变化. 相比之下，其他模型则呈现出不同程度的局限：多元线性回归的标准差普遍偏低；随机森林与XGBoost在部分年份具备较高的相关系数，但其标准差与参考点存在明显偏离；多层感知机在相关性与误差控制的稳定性上相对不足.

综上，U-Net降尺度模型在重建精度、泛化能力方面均表现优异，为后续基于高分辨率LST的煤火异常识别与动态演变分析提供了可靠的数据基础. 该结果也表明，在热红外降尺度这类具有强空间相关性的任务中，融合多尺度上下文特征的深度学习模型，相比传统逐像元机器学习方法具有更突出的适用性与推广潜力.

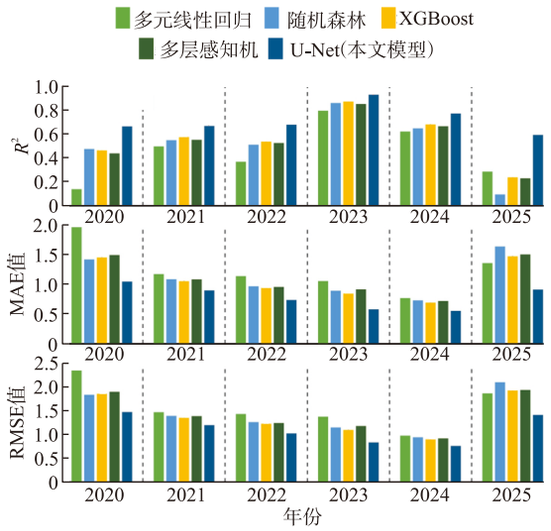


图 9　2020—2025年5种模型降尺度精度对比

Fig. 9　Performance comparison of five downscaling models from 2020 to 2025

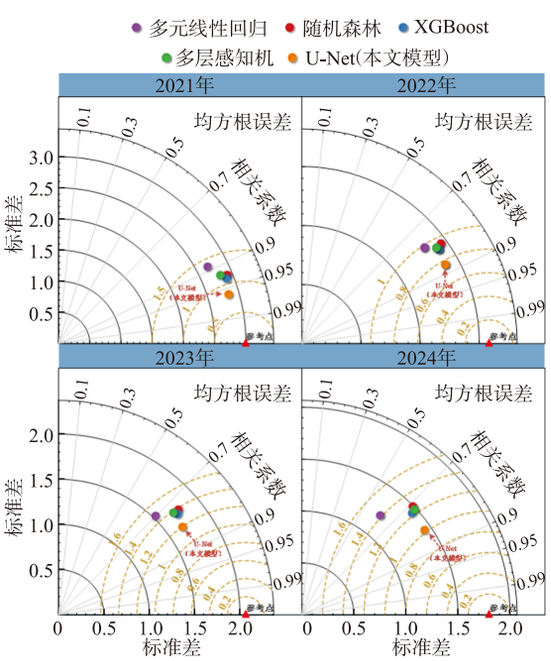


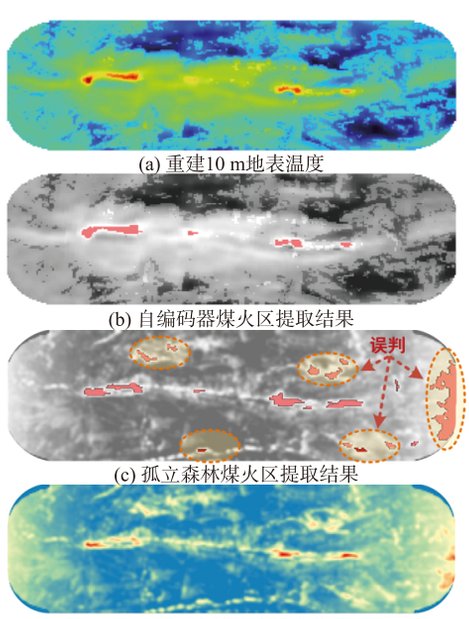
图 10　5种模型的泰勒图对比

Fig. 10　Taylor diagrams comparing five models

4.2　煤火区识别模型的对比分析

基于重建的10 m分辨率地表温度场，本研究选取自编码器与孤立森林2种典型无监督异常检测方法，对煤火区域识别性能进行对比评估．孤立森林是一种基于随机划分的无监督异常检测算法，已在煤火等地表异常探测任务中得到应用[15]．在本研究中，以逐像元的Sentinel-2多波段反射率构建输入向量，通过随机子采样与随机划分生成多棵决策树，利用样本在树中的平均路径长度刻画其“隔离难度”，得到对应的异常分数，用于表征潜在煤火异常像元．

以2024年1～2月的识别结果为例（图11），孤立森林的输出（图11c）虽能检测出煤火引起的高温区域，但在研究区东部等非火区出现了大量零散误判（图11c中虚线标示）．这些误判区域多对应裸露岩石、高反照率地表或地形阴影引起的光谱异常，与煤火活动无关．相比之下，自编码器的识别结果（图11b）显示，所提取的煤火异常区在空间位置与形态上与降尺度地表温度中的高温极值区（图11a）更加吻合．进一步来看，孤立森林输出的异常分数（图11d）在背景区域存在明显波动，反映该方法对地表异质性与随机噪声较为敏感，易产生碎片化异常输出．这主要源于孤立森林基于逐像元特征进行随机划分与隔离评估，缺乏对空间上下文信息的显式建模，因而难以捕捉煤火异常在空间上的连通性与形态特征，在复杂光谱背景下易将局部噪声误判为异常．而自编码器凭借其卷积结构，能够从图像块中学习正常地表温度场的多尺度空间模式，并通过重建残差度量异常：真实煤火区因具有一致的高温空间结构，通常产生连续的高残差响应；而孤立噪声因缺乏稳定空间模式，则能被有效抑制．因此，自编码器在保持高检测率的同时，能够显著降低误报率，提升识别结果的空间可靠性．



(a) 重建10 m地表温度

(b) 自编码器煤火区提取结果

(c) 孤立森林煤火区提取结果

(d) 孤立森林算法异常分数

图 11　煤火区识别结果对比

Fig. 11　Comparison of coal-fire detection results

4.3 局限与展望

本研究构建的煤火区动态监测框架在精度与应用方面取得了良好效果,但在数据条件、方法设计与推广性等方面仍存在一定局限,未来工作可在以下方面进一步完善:首先,在数据支撑层面,由于缺乏系统的治理工程台账资料(如各阶段工程措施的精确起止时间、施工范围等信息),本研究尚未能在定量层面建立治理工程与热异常响应之间的直接对应关系,尚不足以支撑对不同治理措施效率的精细归因与量化评估;其次,在方法设计层面,现有降尺度与识别框架主要依赖热异常信息,尚未显示引入地表反照率、风速、覆盖类型等环境因子的约束,在裸露岩石、高反照率地表或局地热扰动背景下,仍可能出现个别误判,且对深部隐伏火源或早期弱异常的识别敏感性亦有待进一步验证. 最后,模型训练与验证集中于老君庙煤田这一典型区域,虽已通过跨年份测试验证其稳健性,但向不同气候区、开采方式及地质条件下的煤田推广时,仍需更多区域样本与交叉验证以检验其泛化能力.

未来研究可从以下方向深化:其一,加强与矿山管理部门的协作,获取更精细的治理工程台账与监测资料,在遥感温度时序基础上构建定量评价指标体系,从而更精准评估不同治理模式对煤火衰减速率、蔓延路径及复燃风险的影响. 其二,融合多源地质与勘查信息,将煤层厚度、埋深、地层倾角、断层裂隙发育程度、岩性组合及地下水条件等关键特征,与地表温度、地形及覆盖类型共同构建综合特征空间,进而可将煤火高温像元或火区视为图神经网络(GNN)中的节点,依据空间邻近、煤层连通或断层带连通关系构建图结构,通过图卷积或图注意力机制模拟火区在煤层系中的蔓延与相互作用,提升对潜在高风险区域的预测能力. 其三,结合更多高分辨率遥感与实地监测数据,开展跨区域、跨时段的模型迁移与对比试验,探索半监督学习、域自适应等策略,逐步构建适用于区域乃至全国煤火灾害早期识别与动态监管的通用监测框架.

5 结 论

1)基于U-Net模型的地表温度降尺度方法有效提升了热红外数据的空间分辨率,将Landsat 8的LST产品增强至10 m精度. 结果表明,降尺度结果成功刻画了研究区地表温度的精细空间分异特征,为后续煤火精准识别奠定了数据基础.

2)基于自编码器煤火识别方法无需人工标注样本即可实现煤火区域的自动提取,识别结果准确定位了研究区内主要煤火区的空间位置及演化过程,有效克服了传统监督学习方法面临的样本稀缺与类别不平衡问题,为煤火遥感监测提供了高效可行的技术路径.

3)长时序监测结果揭示了煤火灾害的演化特征:2016—2021年间老君庙矿区煤火活动持续活跃,火区面积扩大并呈现连片化趋势;自2022年起,伴随治理工程的有序推进,煤火区面积与热异常强度逐年下降,2024年治理全面展开后成效尤为显著;至2025年,仅残留少量火点,火区面积和热异常指数均降至最低水平,验证了治理工程的显著成效.

未来研究可进一步引入更高分辨率热红外数据、多源地质勘查信息与图结构深度学习模型,构建面向机理揭示与治理优化的煤火综合评估平台,推动遥感监测技术在煤火灾害智能感知领域的应用.

参考文献:

[1] 邓 军,李 贝,王 凯,等. 我国煤火灾害防治技术研究现状及展望[J]. 煤炭科学技术,2016,44(10):1-7.
DENG Jun, LI Bei, WANG Kai, et al. Research status and outlook on prevention and control technology of coal fire disaster in China [J]. Coal Science and Technology, 2016, 44(10): 1-7.

[2] 武建军,蒋卫国,刘晓晨,等. 地下煤火探测、监测与灭火技术研究进展[J]. 煤炭学报,2009,34(12):1669-1674.
WU Jianjun, JIANG Weiguo, LIU Xiaochen, et al. Innovative technologies for exploration, monitoring and extinction of underground coal fires [J]. Journal of China Coal Society, 2009, 34(12): 1669-1674.

[3] SONG Z, KUENZER C. Coal fires in China over the last decade: A comprehensive review [J]. International Journal of Coal Geology, 2014, 133: 72-99.

[4] LIU Y, QI X Y, LUO D Y, et al. Detection and management of coal seam outcrop fire in China: A case study [J]. Scientific Reports, 2024, 14(1): 16.

[5] 李 峰,崔希民,孙广通,等. 无人机热红外遥感煤火探测方法[J]. 煤矿安全,2017,48(12):97-100.
LI Feng, CUI Ximin, SUN Guangtong, et al. Approach of detecting coal fires by unmanned aerial vehicle thermal infrared remote sensing technology [J].

Safety in Coal Mines, 2017, 48(12): 97-100.

[6] 汪云甲,原　刚,王　腾,等.煤田隐蔽火源多源遥感探测研究[J].武汉大学学报(信息科学版),2022,47(10):1651-1661.
WANG Yunjia, YUAN Gang, WANG Teng, et al. Research on multi-source remote sensing detection of concealed fire sources in coalfields [J]. Geomatics and Information Science of Wuhan University, 2022, 47(10): 1651-1661.

[7] 陈云浩,李　京,杨　波,等.基于遥感和GIS的煤田火灾监测研究:以宁夏汝箕沟煤田为例[J].中国矿业大学学报,2005,34(2):97-101.
CHEN Yunhao, LI Jing, YANG Bo, et al. Monitoring coal fires based on remotely sensed data and GIS technique in coalfields: A case study of Rujigou coal field in Nixia, China[J]. Journal of China University of Mining & Technology, 2005,34(2): 97-101.

[8] 蒋卫国,武建军,顾　磊,等.基于夜间热红外光谱的地下煤火监测方法研究[J].光谱学与光谱分析,2011,31(2):357-361.
JIANG Weiguo, WU Jianjun, GU Lei, et al. Monitoring method of underground coal fire based on night thermal infrared remote sensing technology[J]. Spectroscopy and Spectral Analysis, 2011, 31(2): 357-361.

[9] 杜晓敏.热红外遥感煤火探测方法及煤火变化检测[D].北京:中国矿业大学(北京),2015.
DU Xiaomin. Methods for coal fire detection using thermal infrared remote sensing and change detection of coal fires[D]. Beijing: China University of Mining and Technology (Beijing), 2015.

[10] 邱程锦,王　坚,刘立聪,等.遥感技术在乌达煤田火灾监测中的应用[J].煤炭工程,2012(8):130-133.
QIU Chengjin, WANG Jian, LIU Licong, et al. Remote sensing technology applied to fire disaster monitoring and measuring of Wuda coalfield [J]. Coal Engineering, 2012(8): 130-133.

[11] HUO H Y, NI Z Y, GAO C X, et al. A study of coal fire propagation with remotely sensed thermal infrared data[J]. Remote Sensing, 2015, 7(3): 3088-3113.

[12] ROY P, GUHA A, KUMAR K V. An approach of surface coal fire detection from ASTER and Landsat-8 thermal data: Jharia coal field, India[J]. International Journal of Applied Earth Observation and Geoinformation, 2015, 39: 120-127.

[13] CHEN X, PENG J H, SONG Z Y, et al. Monitoring persistent coal fire using Landsat time series data from 1986 to 2020 [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-16.

[14] 马子钧,李元元,武　静,等.顾及地表覆被差异的卫星遥感煤火识别方法[J].煤炭科学技术,2023,51(增2):92-103.
MA Zijun, LI Yuanyuan, WU Jing, et al. Coal fire identification through satellite remote sensing considering the landscapes [J]. Coal Science and Technology, 2023, 51(Sup 2): 92-103.

[15] 朱艳茵,顾皓天,郑　屹,等.联合Landsat 8与Sentinel-2的煤火探测:以将军戈壁矿区为例[J].遥感信息,2025,40(2):149-158.
ZHU Yanyin, GU Haotian, ZHENG Yi, et al. Detecting coal fire areas by using Landsat 8 and Sentinel-2 images: A case study of Jiangjun Gebi Mining Area [J]. Remote Sensing Information, 2025, 40(2): 149-158.

[16] LIU J L, ZHAO F, WANG Y J, et al. Advancing coal fire detection model for large-scale areas based on RS indices and machine learning [J]. International Journal of Applied Earth Observation and Geoinformation, 2025, 140: 104587.

[17] 陈　宇,程惠斌,杜培军,等.地下煤火区遥感探测识别方法研究综述[J].遥感技术与应用,2025,40(4):816-834.
CHEN Yu, CHENG Huibin, DU Peijun, et al. A review of remote sensing detection and identification methods for underground coal fire areas[J]. Remote Sensing Technology and Application, 2025, 40(4): 816-834.

[18] 苏亚东,何　浩,谭崇玖,等.煤矿隐蔽火源多源遥感探测方法[J].地矿测绘,2025,41(2):6-12.
SU Yadong, HE Hao, TAN Chongjiu, et al. Multi-source remote sensing detection methods for hidden fire sources in coal mines[J]. Surveying and Mapping of Geology and Mineral Resources, 2025, 41(2): 6-12.

[19] 华俊玮,祝善友,张桂欣.基于随机森林算法的地表温度降尺度研究[J].国土资源遥感,2018,30(1):78-86.
HUA Junwei, ZHU Shanyou, ZHANG Guixin. Downscaling land surface temperature based on the random forest algorithm [J]. Remote Sensing for Natural Resources, 2018, 30(1): 78-86.

[20] HUTENGS C, VOHLAND M. Downscaling land surface temperatures at regional scales with random forest regression [J]. Remote Sensing of Environment, 2016, 178: 127-141.

[21] KUENZER C, ZHANG J, LI J, et al. Detecting unknown coal fires: Synergy of automated coal fire risk area delineation and improved thermal anomaly extraction [J]. International Journal of Remote Sensing, 2007, 28(20): 4561-4585.

[22] YU B, SHE J, LIU G X, et al. Coal fire identification and state assessment by integrating multitemporal thermal infrared and InSAR remote sensing data: A case study of Midong District, Urumqi, China[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 190: 144-164.

[23] MUJAWDIYA R, CHATTERJEE R S, KUMAR D. A time series decomposition approach to detect coal fires in parts of the Gondwana coalfields of India from VIIRS data [J]. Journal of Spatial Science, 2024, 69(1): 121-136.

[24] SYED T H, RIYAS M J, KUENZER C. Remote sensing of coal fires in India: A review [J]. Earth-Science Reviews, 2018, 187: 338-355.

[25] ZHANG L F, ZHANG L P. Artificial intelligence for remote sensing data analysis: A review of challenges and opportunities[J]. IEEE Geoscience and Remote Sensing Magazine, 2022, 10(2): 270-294.

[26] 王立兵,任予鑫,马 昆,等.多源数据融合智能识别煤矿山场景特征AI模型[J].煤炭学报,2023,48(12):4617-4631.
WANG Libing, REN Yuxin, MA Kun, et al. AI model for intelligent recognition of coal mine scene features through multisource data fusion[J]. Journal of China Coal Society, 2023, 48(12): 4617-4631.

[27] GAUTAM A, GAUTAM R S, SAXENA N. An intelligent wavelet transform-based framework to detect subsurface fires with NOAA-AVHRR images [J]. International Journal of Remote Sensing, 2012, 33(4): 1276-1295.

[28] CHEN Y, DING K W, SUO Z H, et al. A multisource remote sensing identification method for coal fire zones based on a three-layer ensemble learning model[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 12666-12684.

[29] 来 杰,王晓丹,向 前,等.自编码器及其应用综述[J].通信学报,2021,42(9):218-230.
LAI Jie, WANG Xiaodan, XIANG Qian, et al. Review on autoencoder and its application[J]. Journal of Communications, 2021, 42(9): 218-230.

[30] 张重生,陈 杰,李岐龙,等.深度对比学习综述[J].自动化学报,2023,49(1):15-39.
ZHANG Zhongsheng, CHEN Jie, LI Qilong, et al. Deep contrastive learning: A survey[J]. Acta Automatica Sinica, 2023, 49(1): 15-39.

[31] 王小娜,田金炎,李小娟,等.Google Earth Engine云平台对遥感发展的改变[J].遥感学报,2022,26(2):299-309.
WANG Xiaona, TIAN Jinyan, LI Xiaojuan, et al. Benefits of Google Earth Engine in remote sensing [J]. National Remote Sensing Bulletin, 2022, 26(2): 299-309.

[32] 赵艳玲,丁宝亮,何厅厅,等.基于Google Earth Engine的采煤沉陷水体方向变化自动识别[J].煤炭学报,2022,47(7):2745-2755.
ZHAO Yanling, DING Baoliang, HE Tingting, et al. Monitoring of subsidence water body change based on Google Earth Engine[J]. Journal of China Coal Society, 2022, 47(7): 2745-2755.

[33] 张鹏宇,马 砺,石新慧,等.基于时序优化长短期记忆网络的采空区环境多参数预测[J].中国矿业大学学报,2025,54(3):653-666.
ZHANG Pengyu, MA Li, SHI Xinhui, et al. Analysis of slope stability in Laojunmiao opencast coal mine [J]. Journal of China University of Mining & Technology, 2025,54(3):653-666.

[34] 戴妹谊,李恒凯,龙北平,等.融合多源数据的稀土矿区滑坡危险性定量识别方法[J].中国矿业大学学报,2024,53(1):198-210.
DAI Meiyi, LI Hengkai, LONG Beiping, et al. Quantitative identification method of landslide hazard in rare earth mining area based on multi-source data [J]. Journal of China University of Mining & Technology, 2024,53(1):198-210.

[35] 常贵平.老君庙露天煤矿边坡稳定性分析[J].现代矿业,2018,34(2):211-214.
CHANG Guiping. Analysis of slope stability in Laojunmiao opencast coal mine [J]. Modern Mining, 2018, 34(2): 211-214.

(责任编辑 沈 菊 仝 腾)