

融合生境信息的喜马拉雅旱獭洞无人机遥感识别

任红艳¹, 黄坤^{1,2}, 扎西³

1. 中国科学院地理科学与资源研究所 地理信息科学与技术全国重点实验室, 北京 100101;

2. 中国科学院大学资源与环境学院, 北京 100049;

3. 西藏自治区疾病预防控制中心 西藏自治区传染病预防控制重点实验室, 拉萨 850001

摘要: 应用无人机影像与深度学习技术是近年来开展喜马拉雅旱獭识别与活动监测研究的重要手段, 对喜马拉雅旱獭洞的识别是其中的关键环节。然而, 受地形起伏、洞口石块以及土体遮挡等因素影响, 旱獭洞漏检现象突出, 其识别精度有待提升。本研究以西藏地区部分典型鼠疫疫源地为研究区, 通过旱獭洞地面调查与无人机遥感观测, 构建一套包含旱獭洞和洞口附近石块、土体等生境要素的无人机影像数据集, 运用融合生境信息的数据标注策略和YOLOv8、YOLO11、YOLO13、RT-DETR以及RF-DETR等5种目标检测模型, 系统比较传统标注方式与融合生境信息标注策略并评估后者的有效性。结果显示: 在传统标注方式下, 5种目标检测模型识别旱獭洞的精度分别为93.0% (YOLOv8)、91.6% (YOLO11)、85.5% (YOLO13)、76.5% (RT-DETR)、83.0% (RF-DETR); 在融合生境信息的标注策略下, 除YOLOv8模型的洞口识别精度略有降低外(-0.2%), 其余检测模型均有所提升, 分别为2.2% (YOLO11)、9.0% (YOLO13)、16.7% (RT-DETR)、6.5% (RF-DETR)。其中RT-DETR模型与融合生境信息标注策略组合的旱獭洞识别效果提升最明显(约17%), YOLO11模型与融合生境信息标注策略相结合的旱獭洞识别体系效果表现最优。因此, 融合生境信息的标注策略可以降低传统标注方式因遮挡导致的旱獭洞漏检风险, 进而有效提升喜马拉雅旱獭洞的无人机遥感识别效果。本研究提出的数据标注策略有助于提升喜马拉雅旱獭洞的无人机识别效能, 丰富了喜马拉雅旱獭鼠疫疫源地调查的无人机应用体系, 对于青藏高原喜马拉雅旱獭鼠疫的监测与防控具有重要意义。

关键词: 无人机, 深度学习, 数据标注策略, 生境信息, 喜马拉雅旱獭洞, 鼠疫监测

中图分类号: P2

引用格式: 任红艳, 黄坤, 扎西. XXXX. 融合生境信息的喜马拉雅旱獭洞无人机遥感识别. 遥感学报, XX(XX): 1-14

REN Hongyan, HUANG Kun, ZHAXI. XXXX. Drone-based remote sensing identification of himalayan marmot holes integrating habitat information. National Remote Sensing Bulletin, DOI: 10.11834/jrs.20265503]

1 引言

鼠疫是一种由鼠疫耶尔森菌引起的自然疫源性传染病, 其在人间的传播与自然疫源地内啮齿类动物间的鼠疫传播流密切相关(袁星等, 2022)。青藏高原喜马拉雅旱獭鼠疫自然疫源地是我国面积最大、海拔最高且持续活跃的疫源地, 动物间和人间疫情防控形势严峻(向锁玉等, 2020; 王鑫等, 2024)。因此, 在该区域开展啮齿类动物密度及活动特征调查对疫情监测尤为关键。

喜马拉雅旱獭是青藏高原喜马拉雅旱獭鼠疫自然疫源地的主要宿主, 在面向大面积区域开展旱獭密度及其活动特征监测需求下, 传统人工调查效率较低(栾淑丽等, 2021)。随着无人机遥感技术的普及, 其在动物数量调查和分布监测中展现出显著优势(邵全琴等, 2018; 曾志伟等, 2025), 并已成为鼠疫自然疫源地调查的重要手段(黄星魁等, 2023; 崔博超等, 2020)。此外, 尽管喜马拉雅旱獭活动时间与范围存在不确定性, 其洞穴位置却相对固定且受外界环境干扰较小

收稿日期: 2025-12-05; 预印本: XXXX-XX-XX

基金项目: 西藏自治区重点研发项目(编号: XZ202401ZY0071); 第二次青藏高原综合科学考察研究项目(编号: 2019QZKK0607); 西藏自治区揭榜挂帅专项(编号: XZ202403ZY0015)

第一作者简介: 黄坤, 研究方向为无人机遥感的理论和应用。E-mail: huangkun0014@igsrr.ac.cn

通信作者简介: 任红艳, 研究方向为地理信息科学与技术的理论和应用。E-mail: renhy@igsrr.ac.cn

(Wang 和 Hou, 2021)。因此, 利用无人机遥感快速提取洞穴位置并统计数量, 是开展喜马拉雅旱獭密度调查的有效手段。

深度学习目标检测算法的发展, 为无人机遥感影像中目标的快速识别提供了有效手段 (Jiao 等, 2021; Osco 等, 2021; Plaza 等, 2025)。当前主流目标检测算法以卷积神经网络、自注意力机制为基础, 包括 YOLO (You Only Look Once) 系列模型 (Redmon 等, 2016) 及端到端的 DETR (Detection Transformer) 系列模型 (Carion 等, 2020)。相关模型及其变体已广泛应用于遥感目标检测领域, 如基于 E-YOLO 的水利设施识别 (许泽宇 等, 2022), 改进 YOLOv4 的船舶与尾流检测 (Ding 等, 2023), 以及 RT-DETR (Zhao 等, 2024)、RF-DETR (Robinson 等, 2025) 对于船舶、农作物等小目标检测中的应用 (Wang 等, 2024; Sapkota 等, 2025)。

在鼠疫自然疫源地调查中, 目标检测算法已逐渐用于啮齿类动物洞穴识别。基于无人机影像与 YOLOv3, 崔博超等 (2020) 实现了古尔班通古特沙漠大沙鼠鼠洞的识别; Han 等 (2024) 利用改进 YOLOv5 成功识别了内蒙古草原沙鼠洞。然而,

相关研究中仅标注无人机影像中暴露明显的鼠洞洞口, 忽略了部分或全部被遮挡的鼠洞, 导致漏识问题突出, 进而限制了鼠疫自然疫源地调查工作的有效开展。因此, 亟需探索一种可降低洞穴漏检率的数据标注策略, 以提升无人机遥感在鼠疫疫源地监测中的高效应用。

本研究以西藏自治区喜马拉雅旱獭鼠疫自然疫源地中典型疫点区域内的旱獭洞为研究对象, 构建喜马拉雅旱獭洞及其附属生境要素的地面调查与无人机观测数据集, 采用融合生境信息的旱獭洞标注策略, 并结合 5 种目标检测模型, 探索一种新的旱獭洞无人机遥感识别方法。

2 研究区域与数据介绍

2.1 研究流程

图 1 展示了本研究研究开展的基本流程。首先, 在西藏自治区喜马拉雅旱獭鼠疫自然疫源地内的典型疫点区域, 围绕旱獭洞开展地面和无人机同步观测, 利用获取到的旱獭洞及土体、石块等附属物测量数据、照片和影像等信息, 构建面向无人机遥感识别的旱獭洞数据集。

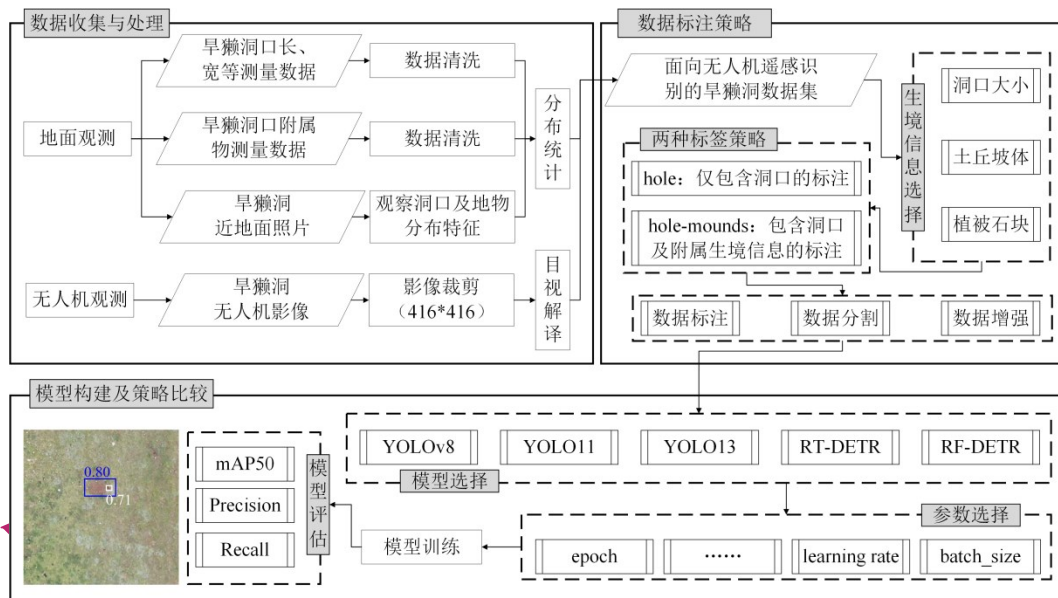


图 1 研究流程图

Fig. 1 Research flowchart

其次, 基于该数据集, 统计并分析旱獭洞口附近石块及土体等信息特征, 提出融合旱獭洞生境信息的标注策略; 最后, 选择 YOLOv8、YOLO11、YOLO13、RT-DETR、RF-DETR 模型评

价不同标注策略的优劣, 利用 $mAP50$ 、 $Precision$ 以及 $Recall$ 等指标评价模型性能与效果, 探索基于融合生境信息标注策略的旱獭洞无人机遥感识别技术。

2.2 采样点数据概况

西藏自治区位于青藏高原西南部,是我国喜马拉雅旱獭鼠疫的主要疫源地之一,近年来动物

间鼠疫持续活跃,人间鼠疫偶有发生(王鑫等, 2024)。本研究在全区17个自然疫源地的25个典型疫点采集数据。

表1 喜马拉雅旱獭洞采样点区域及点位特征

Table 1 Regional and point characteristics of sampling points in Himalayan marmot holes

采样区域	点位编号及位置	点位特征	采样区域	点位编号及位置	点位特征
林芝市	工布江达县 1: (92.4422 E, 29.9247 N)	草甸草原	山南市	加查县 13: (92.7422 E, 29.4247 N)	草甸草原
	朗县 2: (93.5756 E, 28.9578 N)	草甸草原/灌丛/农田		措美县 14: (91.1586 E, 28.4744 N)	草甸草原
	朗县 3: (93.0425 E, 28.9244 N)	草甸草原/灌丛/农田		贡嘎县 15: (91.1753 E, 29.4247 N)	灌丛/农田
	朗县 4: (93.0425 E, 28.8244 N)	草甸草原		当雄县 16: (91.7753 E, 30.5250 N)	草甸草原
那曲市	班戈县 5: (90.6750 E, 31.1086 N)	草甸草原	达孜区 17: (91.4419 E, 29.5581 N)	草甸草原	
	亚东县 6: (89.0581 E, 27.6242 N)	草甸草原	林周县 18: (91.3419 E, 30.0083 N)	草甸草原	
日喀则市	仲巴县 7: (89.0078 E, 27.7742 N)	草甸草原	拉萨市	20: (92.3589 E, 29.6581 N)	草甸草原
	仲巴县 8: (84.3900 E, 29.8581 N)	草甸草原		墨竹工卡县 21: (92.2422 E, 29.7231 N)	草甸草原/农牧交错带
仲巴县 9: (83.0897 E, 30.1917 N)	草甸草原	工卡县 22: (91.9253 E, 29.7247 N)		草甸草原	
普兰县 10: (81.2725 E, 31.0253 N)	草甸草原	23: (91.7419 E, 29.9247 N)		草甸草原	
阿里地区	噶尔县 11: (80.7389 E, 31.2086 N)	草甸草原		尼木县 24: (90.4417 E, 29.3581 N)	草甸草原
	噶尔县 12: (80.4722 E, 32.2422 N)	草甸草原	尼木县 25: (89.9081 E, 29.4081 N)	草甸草原	

2.3 数据采集与预处理

喜马拉雅旱獭活动盛期一般为每年7月至9月(蒋可等, 2024), 本研究于2021-2024年7月份开

展地面测量和低空无人机观测。在典型疫点区域内, 记录旱獭洞及周围土体、石块等附属物形状和大小特征, 同时拍摄洞口照片(图2(a))。



(a) 地面旱獭洞 (a) Ground marmot holes
(b) 平行于地面的旱獭洞口 (b) Marmot holes parallel to the ground

图2 旱獭洞地面照片与无人机影像图(摄于2023年,东经81.2725°,北纬31.0253°)

Fig. 2 Ground photos and drone images of the marmot hole (taken in 2023, 81.2725° E, 31.0253° N)

在开展地面测量的同时, 选用DJI Mavic 2 Pro型号无人机(表2)进行低空观测, 为有效平衡旱獭洞覆盖度与清晰度, 无人机以100米航高获取影像数据。参考郭秀明等(2024)的鼠洞检测流程, 采用416×416窗口裁剪无人机影像(图3), 最终

筛选375张包含旱獭洞的典型样本。至此, 本研究构建了由地面测量数据和无人机观测影像构成的数据集, 包括: (1) 近地面拍摄的旱獭洞照片, 以及实地调查的洞口及附属土体尺寸、石块分布等信息, 为旱獭洞特征挖掘与标注提供依据; (2)

无人机低空俯视影像，展现旱獭洞整体空间分布。

图3 无人机影像图及数据预处理(摄于2023年,东经81.2725°,北纬31.0253°)

Fig. 3 Drone imagery and data preprocessing (taken in 2023, 81.2725° E, 31.0253° N)

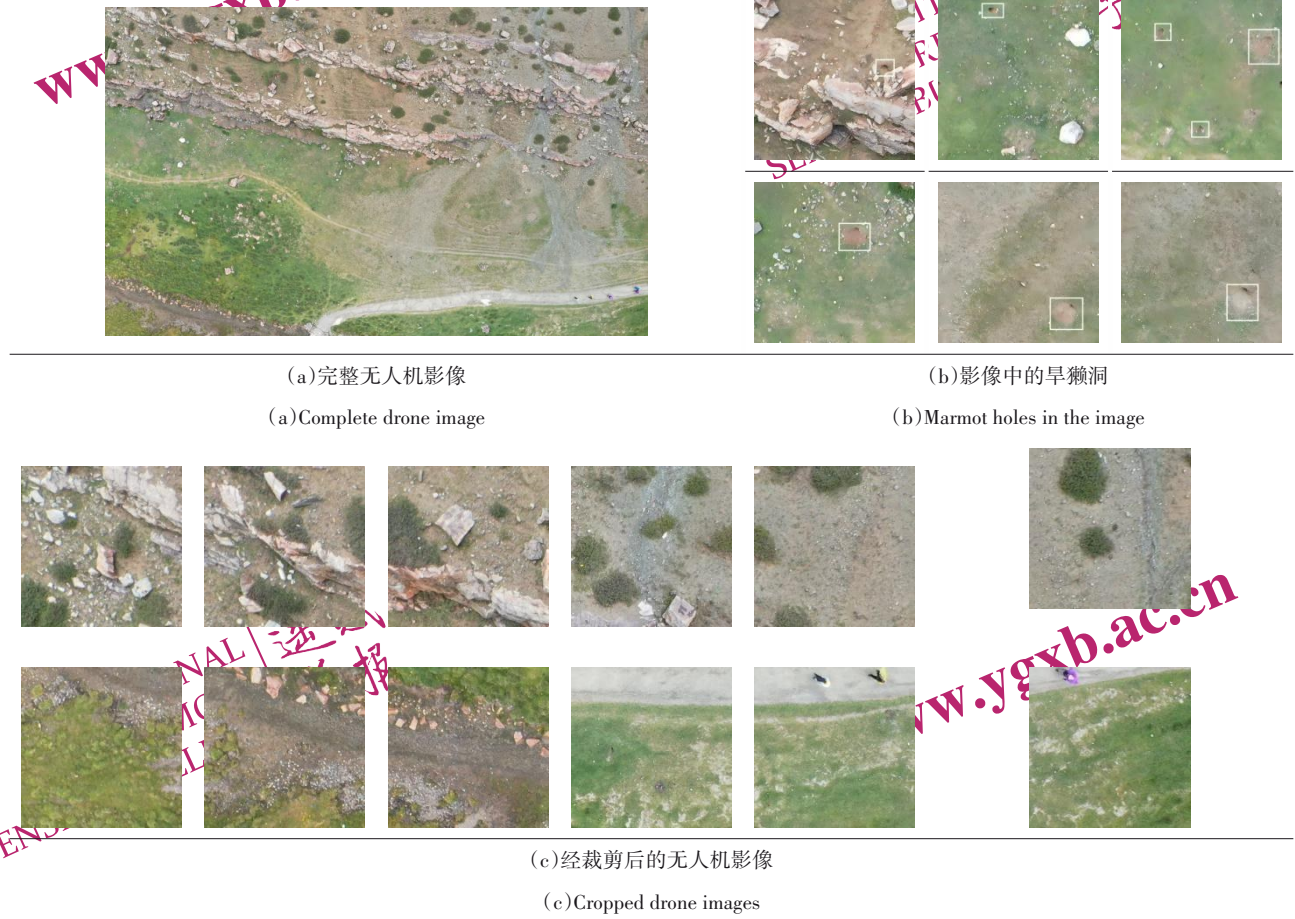


表2 无人机设备参数

Table 2 Parameters of unmanned aerial vehicle equipment

机型(Model)	DJI Mavic Pro 2
重量(Weight)	907g
飞行时间(Flight time)	31m
传感器(Sensor)	1"(CMOS)
有效像素(Effective pixel)	20 million
镜头(Lens)	FOV about 77°, 28 mm (35 mm format equivalent), aperture f/2.8-f/11, shooting range from 1 m to ∞
ISO Range(Photo)	100-3200(auto)
电子快门速度(Electronic shutter speed)	8 - 1/8000 s
静态图像大小(Still image size)	5472 × 3648

3 融合生境信息标注策略的旱獭洞识别模型构建

3.1 数据标注策略

无人机影像标注是旱獭洞识别的关键环节。在仅考虑旱獭洞的传统标注方式中，洞口因近乎

平行于地面或被土体、石块遮挡而未完全暴露在影像内(图2(b))，此时易导致旱獭洞的漏检。因此，通过对无人机影像中石块的遮挡和洞口的土体等情况分析，结合对洞口大小等信息特征挖掘，并将其与旱獭洞融合，提出广义旱獭洞概念，形成一种新的标签策略(式(1))。

$$\begin{cases} \text{hole} = \{cave_i\}_{i=1}^k \\ \text{hole-mounds} = \{cave_i, env_i\}_{i=1}^k \end{cases} \quad (1)$$

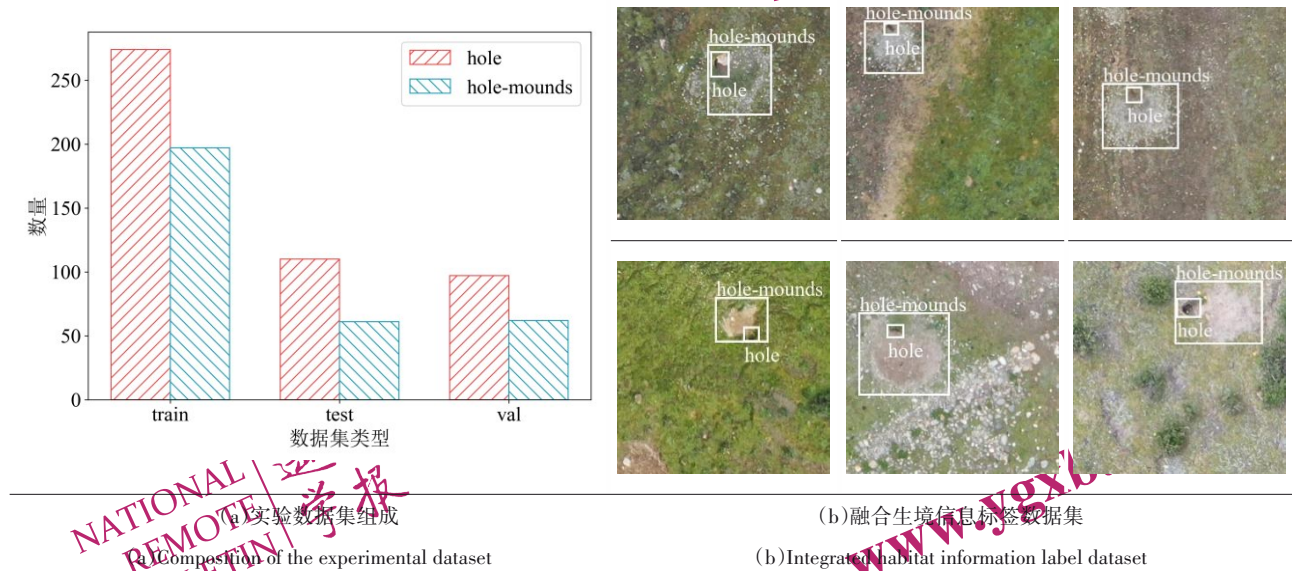
其中, hole 表示采用狭义旱獭洞标注的对象, hole-mounds 表示使用广义旱獭洞标注的对象, $cave_i$ 表示当前标注内容中的旱獭洞对象, env_i 表示

目标对象周围的生境特征, 如土体以及石块等。

在人工严格控制标注对象质量基础上, hole 与 hole-mounds 分别标注得到 481 与 320 个对象 (图4)。

图4 实验数据集组成与标签数据集展示

Fig. 4 Composition of the experimental dataset and presentation of the labeled dataset



3.2 识别模型构建

为减小因单一模型训练结果可能存在偶然性的影响, 研究采用 YOLOv8、YOLO11、YOLO13、RT-DETR 和 RF-DETR 五种模型 (表3) 对实验数据集分别训练。模型训练前, 375 张影像按照 6: 2: 2 比例划分为训练集、测试集以及验证集 (图4)。实验在 Ubuntu 22.04 环境下进行, 处理器为 Intel Xeon Silver 4214R (12 核, 2.40GHz), GPU 为 12GB 显存的 RTX 3080 Ti, 采用 CUDA 加速训练流程。为提升训练效率, 各模型使用公开的小规模预训练权重模型, 训练过程中保证各模型主要超参数的一致性 (表4)。

模型选用 $mAP50$ 为核心评估指标, 辅以精确率 (Precision) 以及召回率 (Recall) 指标进行评价。

$$Precision = TP / (TP + FP) \quad (2)$$

$$Recall = TP / (TP + FN) \quad (3)$$

$$mAP = \sum_{j=1}^M \sum_{i=1}^N P(i) dR(i) / M \quad (4)$$

其中, TP 为真正例, FP 为假正例, FN 为假负例。 P 表示精确率, dR 表示相邻检测框之间的召回率

变化量, N 表示当前类别的检测框总量, M 表示总类别数。 $mAP50$ 表示交并比 IoU (Intersection over Union) 为 0.5 时所有类别平均精度的均值。

表3 五种目标检测模型的组成、特点及应用

Table 3 Composition, characteristics and applications of five object detection models

模型	基本组成	特点	应用
YOLOv8	主干网络采用改进 CSPDarknet 架构, 颈部网络由特征金字塔与路径聚合网络组成, 检测头采用无锚框设计。	具备多尺度目标检测能力, 有较快检测速度与较高检测精度。	由 Ultralytics (2023) 发布, 目前已应用于森林野火监测 (Michail 等, 2024), 合成孔径雷达影像中的船舶检测 (Im 和 Lee, 2024) 等领域。
YOLO11	主干网络采用改进 C3K2 模块, 颈部网络嵌入 C2PSA 模块与空间金字塔池化层, 检测头引入深度可分离卷积层。	C3K2 与 C2PSA 模块具备更高效的特征提取能力, 较 YOLOv8 的检测速度与精度更高。	由 Ultralytics (2024) 发布, 目前已应用于街景图像中路面检测 (Randhawa 等, 2025), 广阔区域内民用飞机监视和探测 (Li 等, 2025)
YOLO13	主干网络采用轻量化模块 DS-C3K2 替代传统的大核卷积, 引入了超图增强模块以及全流程分发网络。	可建模多目标的复杂语义关系, 提升小目标检测和遮挡场景下的性能。	由 Lei 等人 (2025) 提出, 目前已在人机交互的手势识别任务中开展应用 (Gao 等, 2025)。
RT-DETR	主干网络采用 HGNet-v2 作为特征提取网络, 舍去了传统的检测流程中的非极大值抑制流程以及锚框检测流程, 采用一种高效的混合编码器来处理多尺度特征。	兼顾了目标检测过程中的高效性与实时性, 对小目标以及密集目标的检测效果较优。	由 Zhao 等人 (2024) 提出, 目前已广泛应用于遥感图像小目标检测任务中 (Li 等, 2025; 沈涛等, 2025)。
RF-DETR	使用单一尺度的主干网络提取图像特征图, 通过将 LW DETR 与预训练的 DFNOv2 主干网络结合。	参数量相对较小, 在检测过程中保持较高精度与较低延迟。	由 Robinson 等人 (2025) 提出, 目前已在遥感影像小目标实时检测 (Borges 和 Sablatnik, 2025) 以及农作物检测中 (Sapkota 等, 2025) 开展应用。

表4 主要实验参数

Table 4 Key experimental parameters

环境配置	硬件(软件)参数	训练参数	训练参数值
内存大小	90 GB	划分比例	6:2:2
Python 版本	3.12	epoch	600
PyTorch 版本	2.8.0	batch_size	4
CUDA 版本	12.8	lr	0.0001

4 旱獭洞识别结果

4.1 广义旱獭洞生境信息特征

基于对 25 个疫点共计 159 个旱獭洞的实地调查数据分析表明: 喜马拉雅旱獭洞洞口及周围土体的形状、尺寸具有明显共性特征。

在洞口特征方面, 研究区内的旱獭洞洞口形状多为圆形或椭圆形, 长约 10-74 厘米, 平均 27.26 厘米; 宽约 8-65 厘米, 平均 29.84 厘米 (图 5)。部分区域中与喜马拉雅旱獭洞穴混合分布的其它鼠兔洞穴, 因洞口长宽普遍小于 10 厘米, 可与旱獭洞明确区分。

在调查的 159 个旱獭洞中, 156 个 (约 98%) 洞口周围均存在扇形或彗星状土体, 其坡体长约 23-290 厘米, 平均 126.25 厘米; 宽约 12-250 厘米, 平均 126.04 厘米 (图 6)。在荒漠区域, 土体

颜色与周围地表差异显著, 易辨识; 在有石块覆盖区域, 土体覆盖植被, 形成局部裸露斑块, 成为隐蔽洞口的间接标志。

4.2 模型性能与效果评价

4.2.1 融合生境信息策略的可行性

模型训练总损失包括分类、定位以及置信度损失, 其反映了模型训练过程中对 hole 以及 hole-mounds 特征的学习能力。训练结果表明 (图 6 (a)), RT-DETR 模型最终损失最低且波动小, RF-DETR 次之, YOLO 系列模型在训练过程中的损失相对较高但最终稳定在 2.5 左右。各模型整体收敛情况良好, 说明均能有效学习旱獭洞及其附属生境特征, 验证了融合生境信息标注策略的可行性。


4.2.2 融合生境信息策略的有效性

经迁移学习训练后, 各模型评估指标均随轮次增加趋于稳定 (图 6 (b) - (d)), 表明模型均实现了有效学习, 其中 RF-DETR 前期上升最快, YOLO 系列模型其次, RT-DETR 则相对缓慢。


表 5 体现了融合生境信息的标注策略整体优于传统标注策略。除 YOLOv8 的 *mAP50* (hole-mounds) 略低于 *mAP50* (hole), 其余模型均有不

同程度提升，其中 RT-DETR 提升幅度最大 (16.7%)。整体来看，DETR 系列模型提升显著，


可能与自注意力机制增强了对生境特征的学习相关。




(a) 旱獭洞口长度
(a) Marmot hole length



(b) 旱獭洞口宽度
(b) Marmot hole width



(c) 旱獭洞周围土体长度
Length of the mound surrounding the marmot hole



(d) 旱獭洞周围土体宽度
Width of the mound surrounding the marmot hole

图5 旱獭洞口及周围土体长度与宽度分布

Fig. 5 Distribution of the length and width of the marmot hole and the surrounding mound

综合考虑各指标表现，YOLO11 在五种测试模型中表现最佳。以 $mAP50$ (整体) 和 $mAP50$ (hole-mounds) 为核心评价指标，结合 *Precision*、*Recall* 辅助分析可知，YOLO11 的 $mAP50$ (hole-mounds) 达到 0.936，处于最高水平。在整体检测性能方面，YOLO11 的 $mAP50$ (整体) 与 *Recall* 指标仅次于 YOLOv8，处于较高水平。相比之下，其他模型在关键指标上均存在一定不足：YOLOv8 在反映生境融合能力的关键指标 $mAP50$ (hole-mounds) 上表现不及 YOLO11；而 RF-DETR、YOLO13 与 RT-DETR 在核心指标上均明显落后。

4.2.3 标注策略消融实验

为进一步的验证融合生境信息标注策略的必要性与有效性，研究设计了消融实验进行验证。其中必要性检验是在不考虑融合生境信息条件下，仅采用小目标检测模型对 hole 对象进行检测，判断其是否能够同样达到 hole-mounds 识别精度；有


效性则旨在区分生境信息引入与目标框尺寸增大对精度提升的不同贡献程度。

针对必要性检验，结合实验数据集中目标稀疏分布以及尺寸较小等特性，研究采用小目标检测领域经典模型 THP-YOLOv5 (Zhu 等, 2021) 以及针对遥感图像小目标检测的 FFCA-YOLO (Zhang 等, 2024) 模型进行测试。此外，对于基础实验中 hole 识别精度较差的 YOLO13 (YOLO 系列) 与 RT-DETR (DETR 系列) 模型，引入 P2 检测头改进模型架构，以提升对小目标检测效果。P2 检测头设计理念由 Lin 等 (2017) 等提出，其对应 1/4 原始输入分辨率的高分辨率特征分支，相比于 YOLO13 与 RT-DETR 中的 P3, P4, P5 检测头，P2 检测头可以有效减少小目标在深层下采样中的特征信息丢失问题，是目前针对小目标检测广泛使用的有效改进方法。

在实验过程中，保持训练数据划分比例、模型结构以及超参数 (表 4) 一致的情况下对必要性


检验要求中的各模型进行训练。实验结果显示(图7,表6),TPH-YOLOv5针对hole的最佳表现精度为0.876,FFCA-YOLO为0.853,两者均低于大部分通用模型针对hole与hole-mounds的检测效果,这可能与旱獭洞分布稀疏、被遮挡等特性相

关。融合了P2检测头的YOLO13-P2与RT-DETR-P2对于hole识别精度为0.892,0.819,高于YOLO13(0.855)以及RT-DETR(0.765),但均低于对应模型在hole-mounds下的识别精度(0.932与0.893)。




(a) 不同模型损失函数变化

(a) Variations in loss functions across different models




(b) $mAP50$ 随训练轮次变化

(b) $mAP50$ over training epochs



(c) Precision随训练轮次变化

(c) Precision over training epochs



(d) Recall随训练轮次变化

(d) Recall over training epochs

图6 模型损失及主要精度指标随训练轮次变化

Fig. 6 Model loss and main accuracy indicators change with the number of training rounds

表5 各模型及不同标注策略精度表现

Table 5 Accuracy performance of each model and different annotation strategies

Model	YOLOv8	YOLO11	YOLO13	RT-DETR	RF-DETR
$mAP50$ (整体)	0.932	0.926	0.911	0.867	0.910
$mAP50$ (hole)	0.930	0.916	0.855	0.765	0.830
$mAP50$ (hole-mounds)	0.928	0.936	0.932	0.893	0.884
Precision(整体)	0.875	0.860	0.885	0.884	0.910
Recall(整体)	0.897	0.888	0.843	0.793	0.860

上述结果表明,仅依靠小目标检测模型优化难以实现旱獭洞的有效识别,且相较于模型架构改进所需的高

成本,融合生境信息的标注策略仅通过优化数据标注流程即可实现较高精度检测,验证了该策略在旱獭洞检测任务中的必要性。

针对有效性检验要求,研究选择以hole检测框为中心,采用与hole-mounds相同的尺寸大小,构建一系列包含旱獭洞口与不完整生境信息的hole-mixture对象,同时采用YOLOv8、YOLO11、YOLO13、RT-DETR以及RF-DETR模型对hole-mixture对象进行训练。同样保证与表4一致的主要参数设置,实验结果如图7所示。各模型 $mAP50$ 最佳精度表现分别为0.906(YOLOv8),0.899(YOLO11),0.882(YOLO13),0.851(RT-DETR)与0.877(RF-DETR)。对比传统标注方式

及融合生境策略下的模型精度(表7)可知, 单纯扩大旱獭洞标注框尺寸、却破坏洞口与附属生境信息完整空间关系的方法, 精度均低于相同模型条件下的hole-mounds识别精度。

表6 hole的小目标模型检测精度对比

Table 6 Comparison of hole's small target model detection accuracy

模型类型	模型名称	hole- <i>mAP50</i> (hole-mounds- <i>mAP50</i>)
基础模型	YOLO13	0.855(0.932)
	RT-DETR	0.765(0.893)
P2检测头改进模型	YOLO13-P2	0.892
	RT-DETR-P2	0.819
专用小目标检测模型	TPH-YOLOv5	0.876
	FFCA-YOLO	0.853

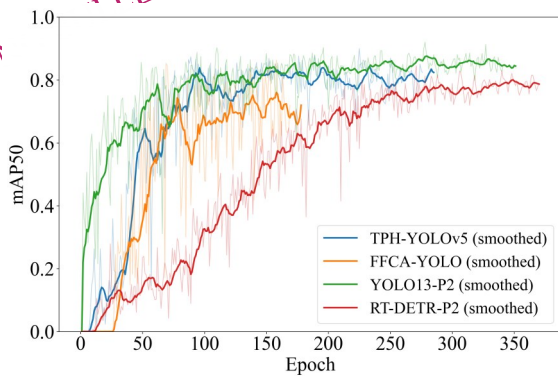
注: 表6中括号内数值代表对应模型下的hole-mounds识别精度

因而, 本文提出的hole-mounds标注策略是有效的, 其对旱獭洞识别精度的提升作用, 主要源于将洞口与生境信息完整地纳入标注流程这一核

心步骤, 该部分贡献大于单纯增大标注框尺寸的影响, 表明具有完整空间约束的生境信息是提升旱獭洞识别精度的关键因素。

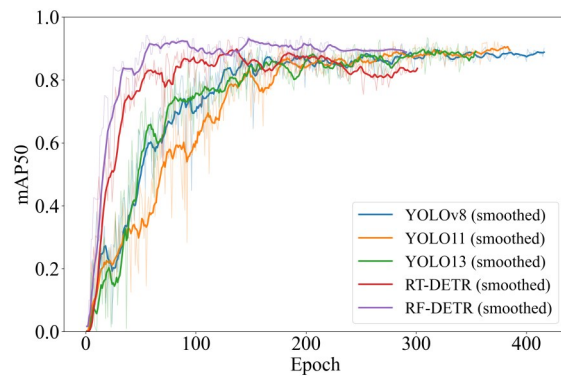
4.3 识别结果

基于不同标注策略的模型检测结果(图8), 其中白框代表hole, 蓝框代表hole-mounds, 数值代表置信度)可知融合生境信息标注策略在解决目标漏识问题上的突出优势。图8(b)-(f)、图8(h)-(l)与图8(n)-(r)表示不同模型的检测效果, 其中在图(n)-(r)中, 仅YOLOv8成功识别出其中被遮挡的hole对象, 其余四种模型均出现漏检。而采用融合生境信息标注的hole-mounds对象, 可由YOLOv8、YOLO11及RF-DETR共同检测到——这表明, 即使旱獭洞在无人机影像中存在部分或完全遮挡, 通过引入生境信息作为辅助信息的hole-mounds对象, 也能成功识别出被遮挡旱獭洞, 充分验证了融合生境信息策略的有效性。



(a) hole训练过程中*mAP50*变化

(a) *mAP50* changes during the training process of hole



(b) hole-mixture训练过程中*mAP50*变化

(b) *mAP50* changes during the training process of hole-mixture

图7 四种小目标检测模型对hole检测结果及五种模型对hole-mixture检测结果

Fig. 7 Detection results of hole by four small target detection models and detection results of hole-mixture by five models

表7 hole、hole-mounds与hole-mixture检测精度对比

Table 7 Comparison of detection accuracy of hole, hole-mounds and hole-mixture

Model	YOLOv8	YOLO11	YOLO13	RT-DETR	RF-DETR
<i>mAP50</i> (hole)	0.930	0.916	0.855	0.765	0.830
<i>mAP50</i> (hole-mounds)	0.928	0.936	0.932	0.893	0.884
<i>mAP50</i> (hole-mixture)	0.906	0.899	0.882	0.851	0.877

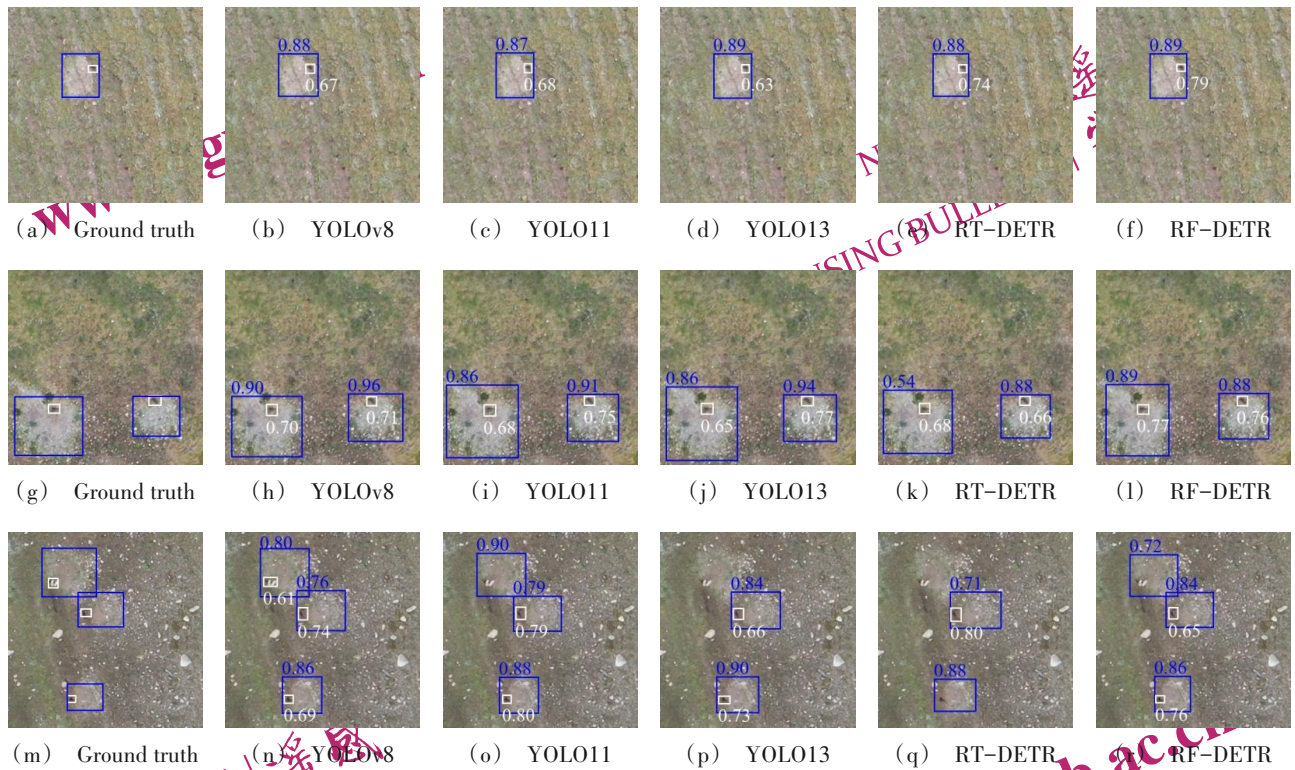


图8 各模型针对不同标注策略的识别结果

Fig.8 Recognition results of each model for different annotation strategies

5 结论

研究区域内旱獭洞的洞口、土体长宽以及石块分布等具有明显共性特征，这与张龙等（2019）对喜马拉雅旱獭洞穴物理特征统计结果基本一致。在传统标注方式下，受洞口土体、石块等遮挡影响，狭义旱獭洞常因难以被无人机识别而导致漏检。然而，这些共性特征却能被高分辨率无人机遥感影像有效观测到，通过将特征凝练为生境信息，并纳入数据标注过程，有效提升了旱獭洞的识别精度。受实验条件所限，本研究仅考虑了易于观察、局部的生境信息，后续研究可通过拓展地面调查，系统挖掘更多可利用的生境信息，进而丰富数据标注内容、优化标注策略，进一步提升模型检测精度。

表5展示了五种检测模型对 hole-mounds 及 hole 的识别效果，结果显示，各类模型在融合生境信息的标注策略均表现优异，印证了本研究标注策略的有效性。多数模型对 hole-mounds 的识别效果更优，仅 YOLOv8 模型中 hole 的识别精度较 hole-mounds 高出 0.2%。这是因为不同模型因结构差异，在特征提取与融合方面表现不一，导致识

别精度有所波动。后续可通过对比 YOLOv8 与其它模型在损失函数设计、特征金字塔选择等关键环节上的差异，明确影响 hole-mounds 识别的核心环节，优化网络结构，以提升整体识别精度。

基于 4.2.3 节的标注策略消融实验，可知融合生境信息的标注策略是提升旱獭洞识别精度的一种低成本且有效的手段，其中精度的提升主要源于生境信息的引入，而非目标框尺寸的扩大。消融实验结果表明，即便采用小目标检测模型，其对 hole 的识别精度仍低于融合生境信息标注策略下模型对 hole-mounds 的检测效果。这说明仅依靠小目标检测模型的架构设计，难以有效降低旱獭洞的漏检率；且相较于模型架构改进的高成本，融合生境信息的标注策略能以更低的实施成本，实现更优的检测精度。此外，基于表 7 中对于 hole-mixture 的识别精度均低于相同模型下的 hole-mounds 识别精度可知，具有完整空间约束的生境信息是提升旱獭洞识别精度的关键因素。结合实地调查结果可知，98% 的旱獭洞周围均存在明显的土体、石块等生境要素，两者具有强相关的空间关系。hole-mounds 标注策略能够充分捕捉这种空间关联，通过在标注阶段有序完整地将附属要

素纳入洞口识别中,使得模型能够在特征学习中同时关注洞口形态、土体形状与颜色等组合特征,从而有效降低了无人机影像下的旱獭洞漏检率。

将生境信息融入目标检测,本质是通过引入上下文信息,缓解孤立目标因特征不显著而导致的识别困难问题(Jamali等,2025)。上下文信息可分为先验知识、局部、全局三个层次以及时间、空间、其它三大类别(Galleguillos和Belongie,2010;Wang和Zhu,2023)。当前遥感领域的上下文信息补充多集中于局部层次,并基于时空以及光谱等类别展开,通常在模型构建与训练阶段实现(Zhang等,2023;骆剑承等,2021)。本研究创新地在标注阶段引入空间类别下的局部上下文信息,通过关联旱獭洞口与其相邻的生境信息要素,有效降低目标漏识率,为上下文辅助目标检测研究提供了新思路。然而,本研究仅基于西藏自治区部分区域旱獭洞样本进行分析,覆盖范围有限。故而,所提方法能否迁移至青海、藏东等面积更广、海拔更高且生境异质性更明显的喜马拉雅旱獭鼠疫源地,仍需进一步验证。

6 结论

喜马拉雅旱獭洞在无人机影像中的准确识别对于鼠疫自然疫源地监测至关重要。本研究提出了一种融合生境信息的喜马拉雅旱獭洞无人机遥感识别方法,创新地将生境信息融入数据标注过程。基于西藏自治区典型鼠疫自然疫源地的实地调查数据,构建了面向无人机遥感识别的旱獭洞数据集,采用五种检测模型对比两种标注策略的优劣,并筛选表现最优的模型,得到如下结论:

(1) 融合生境信息的标注策略显著优于传统标注策略。在YOLO11, YOLO13, RT-DETR以及RF-DETR模型中的识别精度平均提升了8.6%,且通过消融实验验证了该策略的必要性与有效性。

(2) 基于YOLO11的旱獭洞检测模型表现最优。在融合生境信息策略下,其hole-mounds的 $mAP50$ 达到最高水平(93.6%);在综合两种策略时,其整体 $mAP50$ 与Recall指标亦保持较高水平。

(3) 生境特征的融入优化了旱獭洞目标特征表达。通过将土体、石块等作为上下文信息补充,有效增强了旱獭洞的影像特征,缓解了因遮挡导致的漏检现象,提升了复杂场景下的旱獭洞检测

的鲁棒性。

本研究的结果证实了将喜马拉雅旱獭洞附属生境信息融入相关检测任务中的可行性与有效性,结合无人机遥感技术与该标注策略能有效提升对喜马拉雅旱獭洞识别精度,且基于YOLO11构建的识别模型在该场景下的表现最佳。本研究所提出的融合生境信息的标注策略拓宽了传统目标检测任务中的对象标注环节思路,对类似小目标、复杂情景下的对象识别检测任务有启发和示范作用。目前实验数据集已公布,可通过相关链接(<https://doi.org/10.57760/sciencedb.35069>)进行访问。

志 谢 感谢逯伟利、徐南康、马昊天等研究人员在相关数据收集与处理过程中的贡献,同时感谢西藏自治区疾控中心龚弘强研究员在研究过程中提供的工作协调!

参考文献(References)

- Burges M and Sabbing R. 2025. Near Real Time Explainable Detection of Small Objects in Remote Sensing//Asian Conference on Pattern Recognition. Singapore: Springer: 33-47 [DOI: 10.1007/978-981-95-4395-3_3]
- Carion N, Massa F, Synnaeve G, Usunier N, Kirillov A and Zagoruyko S. 2020. End-to-end object detection with transformers//European Conference on Computer Vision. Cham: Springer: 213-229 [DOI: 10.1007/978-3-030-58452-8_13]
- Cui B C, Zheng J H, Liu Z J, Ma T, Shen J L and Zhao X M. 2020. YOLOv3 Mouse Hole Recognition Based on Remote Sensing Images from Technology for Unmanned Aerial Vehicle. *Scientia Silvae Sinicae*, 56(10): 199-208 (崔博超, 郑江华, 刘忠军, 马涛, 沈江龙, 赵雪迷. 2020. 无人机遥感影像的YOLOv3鼠洞识别技术. *林业科学*, 56(10): 199-208 [DOI: 10.11707/j.1001-7488.20201022])
- Ding K Y, Yang J F, Lin H, Wang Z, Wang D Y, Wang X H, Ni K and Zhou Q. 2023. Towards real-time detection of ships and wakes with lightweight deep learning model in Gaofen-3 SAR images. *Remote Sensing of Environment*, 284: 113345 [DOI: 10.1016/j.rse.2022.113345]
- Galleguillos C and Belongie S. 2010. Context based object categorization: a critical survey. *Computer Vision and Image Understanding*, 114(6): 712-722 [DOI: 10.1016/j.cviu.2010.02.004]
- Gao Y F, Luo W, Zhang S S, Ahmad N S, Wang X J and Goh P. 2025. Benchmarking YOLOv8 to YOLOv13 for robust hand gesture recognition in human - robot interaction. *Scientific Reports*, 15(1): 40043 [DOI: 10.1038/s41598-025-23925-9]
- Guo X M, Wang D W, Liu S P, Zhu Y P, Liu X H, Lin K J, Wang J Y

- and Li F. 2024. Study on key problems for rat hole recognition and count near ground based on deep learning and its application. *Acta Agriculturae Zhejiangensis*, 36(9): 2146-2154 (郭秀明, 王大伟, 刘升平, 诸叶平, 林晓辉, 林克剑, 王佳宇, 李非. 2024. 基于深度学习的近地面草原鼠洞识别计数关键问题研究与应用. *浙江农业学报*, 36(09): 2146-2154 [DOI: 10.3969/j.issn.1004-1524.20230858])
- Han Y, Bai X Y, Gao X C, Cheng H R and Zhou K X. 2024. Grassland Mouse Hole Recognition Model Based on UAV Remote Sensing and Improved YOLOv7//2024 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Sarawak: IEEE: 4340-4345 [DOI: 10.1109/SMC54092.2024.10831587]
- Huang X K, Zhao J, Pan H H, Xia G H and Zhang T C. 2023. Research progress on the application of "3S" technology in plague prevention and control. *Chinese Journal of Vector Biology and Control*, 34(6): 824-827 (黄星魁, 赵俊, 潘欢弘, 夏光辉, 张天琛. 2023. "3S"技术在鼠疫防控中的应用研究进展. *中国媒介生物学及控制杂志*, 34(6): 824-827 [DOI: 10.11853/j.issn.1003.8280.2023.06.022])
- Im Y Y and Lee Y W. 2024. Ship Detection in Satellite Images from Radar and Optical Sensors Using YOLO//International Geoscience and Remote Sensing Symposium. Athens: IEEE: 8949-8953 [DOI: 10.1109/IGARSS53475.2024.10642358]
- Jamali M, Davidsson P, Khoshkangini R, Ljungqvist M G and Mihalescu R. 2025. Context in object detection: a systematic literature review. *Artificial Intelligence Review*, 58(6): 1-89 [DOI: 10.1007/s10462-025-11186-x]
- Jiang K, Xiong H M, Jin H X, Tian F Z, Li W, Wei Y W, Ma Y, He J, Su X D and Mi B Y. 2024. Research progress on ecology of *Marmota himalayana*. *Chinese Journal of Vector Biology and Control*, 35(1): 121-127 (蒋可, 熊浩明, 靳海晓, 田富彰, 李伟, 魏有文, 马英, 何建, 苏晓东, 米宝玉. 2024. 喜马拉雅旱獭生态学研究进展. *中国媒介生物学及控制杂志*, 35(01): 121-127 [DOI: 10.11853/j.issn.1003.8280.2024.01.022])
- Jiao L C, Wang D, Bai Y D, Chen P H and Liu F. 2021. Deep learning in visual tracking: A review. *IEEE Transactions on Neural Networks and Learning Systems*, 34(9): 5497-5516 [DOI: 10.1109/TNNLS.2021.3136907]
- Lei M Q, Li S Q, Wu Y H, Hu H, Zhou Y, Zheng X H, Ding G G, Du S Y, Wu Z Z and Gao Y. 2025. YOLOv13: Real-Time Object Detection with Hypergraph-Enhanced Adaptive Visual Perception. *arXiv preprint arXiv:2506.17733* [DOI: 10.48550/arXiv.2506.17733]
- Li J, Shi H L, Hong Q H and Jia Y. 2025. A Scale-Aware Multi-Domain DETR for Small Object Detection in UAV Remote Sensing Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 63:1-20 [DOI: 10.1109/TGRS.2025.3624765]
- Li L Y, Zhou X X, Zhang W C, Zhong Y F, Gao L, Yu J N, Li X Y and Chen F S. 2025. Thermal sentinel: Low-earth orbit infrared intelligent system for flying civil aircraft safety. *Remote Sensing of Environment*, 328: 114826 [DOI: 10.1016/j.rse.2025.114826]
- Lin T -Y, Dollár P, Girshick R , He K M, Hariharan B and Belongie S. 2017. Feature pyramid networks for object detection//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE: 936-944 [DOI: 10.1109/CVPR.2017.106]
- Luan S L, Ren H Y and Shi R H. 2021. Research progress on identification and monitoring of the appropriate habitat of Himalayan marmot. *Chinese Journal of Endemic Diseases*, 40(12) : 1024-1030. (栾淑丽, 任红艳, 施润和. 2021. 喜马拉雅旱獭适生地识别与监测研究进展. *中华地方病学杂志*, 40(12): 1024-1030 [DOI: 10.3760/cma.j.cn231583-20210121-00018])
- Luo J C, Wu X D, Wu T J, Liu W, Xia L G, Yang H P, Sun Y W, Xu N, Zhang X, Shen Z F and Zhou N. 2021. Research on intelligent calculation model and method of precision land use/cover change information driven by high-resolution remote sensing. *National Remote Sensing Bulletin*, 25(7): 1351-1373 (骆剑承, 胡晓东, 吴田军, 刘巍, 夏列钢, 杨海平, 孙营伟, 徐楠, 张新, 沈占锋, 周楠. 2021. 高分遥感驱动的精准土地利用与土地覆盖变化信息智能计算模型与方法研究. *遥感学报*, 25(7): 1351-1373 [DOI: 10.11834/jrs.20219402])
- Ma Y, Liu P B, Li Z Y, Yue Y G, Zhao Y M, He J, Zhao J X, Song X P, Wang J, Liu Q Y and Lu L. 2024. High genetic diversity of the himalayan marmot relative to plague outbreaks in the Qinghai-Tibet Plateau, China. *BMC genomics*, 25(1): 262 [DOI: 10.1186/s12864-024-10171-y]
- Michail E, Bozas A, Stefanopoulos D, Paspatakis S, Orfanidis G and Moutzidou A. 2024. Incorporating Social Media Sensing and Computer Vision Technologies to Support Wildfire Monitoring//IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium: Athens: IEEE: 2082-2085 [DOI: 10.1109/IGARSS53475.2024.10641848]
- Osco L P, Junior J M, Ramos A P M, de Castro Jorge L A, Fatholahi S N, de Andrade Silva J, Matsubara E T, Pistori H, Gonçalves W N and Li J. 2021. A review on deep learning in UAV remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 102: 102456 [DOI: 10.1016/j.jag.2021.102456]
- Plaza J, Sánchez N, Santiago-Aliste A, Charfolé J F and Pérez-Sánchez R. 2025. Deep Learning and Drone Imagery for the Automatic Detection and Quantification of Common Vole Burrows in Agricultural Landscapes. *Smart Agricultural Technology*, 12: 101529 [DOI: 10.1016/j.atech.2025.101529]
- Randhawa S, Aygün E, Randhawa G, Herfort B, Lautenbach S and Zipf A. 2025. Paved or unpaved? a deep learning derived road surface global dataset from mapillary street-view imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 223: 362-374 [DOI: 10.1016/j.isprsjrs.2025.02.020]
- Redmon J, Divvala S, Girshick R, and Farhadi A. 2016. You only look once: Unified, real-time object detection//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE: 779-788 [DOI:10.1109/CVPR.2016.91]
- Robinson I, Robicheaux P, Popov M, Ramanan D and Peri N. 2025. RF-DETR: Neural Architecture Search for Real-Time Detection Transformers. *arXiv preprint arXiv:2511.09554* [DOI: 10.48550/arXiv.2511.09554]
- Sapkota R, Cheppally R H, Sharda A, and Karkee Manoj. 2025. RF-

- DETR Object Detection vs YOLOv12: A Study of Transformer-based and CNN-based Architectures for Single-Class and Multi-Class Greenfruit Detection in Complex Orchard Environments Under Label Ambiguity. arXiv preprint arXiv:2504.13099 [DOI: 10.48550/arXiv.2504.13099]
- Shao G Q, Guo X J, Li Y Z, Wang Y C, Wang D L, Liu J Y, Fan J W and Yang F. 2018. Using UAV remote sensing to analyze the population and distribution of large wild herbivores. *Journal of Remote Sensing*, 22(3): 497 - 507 (邵全琴, 郭兴健, 李愈哲, 汪阳春, 王东亮, 刘纪远, 樊江文, 杨帆. 2018. 无人机遥感的大型野生食草动物种群数量及分布规律研究. *遥感学报*, 22(3): 497 - 507 [DOI: 10.11834/jrs.20187267])
- Shen T, Zhang X Z and Xu D. 2025. Improved RT-DETR Algorithm for Small Object Detection in Remote Sensing Images. *Computer Science*, 52(8): 214-221 (沈涛, 张秀再, 许岱. 2025. 改进RT-DETR的遥感图像小目标检测算法. *计算机科学*, 52(08): 214-221 [DOI: 10.11896/jcsj.241000019])
- Wang A R, Xu Y, Wang H, Wu Z B and Wei Z H. 2024. CDE-DETR: A real-time end-to-end high-resolution remote sensing object detection method based on RT-DETR. *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium*. Athens: IEEE: 8090-8094 [DOI: 10.1109/IGARSS53475.2024.10641003]
- Wang S L and Hou F J. 2021. Burrow characteristics and ecological significance of *Marmota himalayana* in the northeastern Qinghai-Tibetan Plateau. *Ecology and Evolution*, 11(13): 9100-9109 [DOI: 10.1002/ece3.7754]
- Wang X, Jing H Q and Kan B. 2024. A long way to go-the prevalence, prevention, and control of plague in the contemporary era. *China Tropical Medicine*, 24(1): 22-27 (王鑫, 景怀琦, 阚斌. 2024. 道阻且长——鼠疫在当今社会的流行与防控. *中国热带医学*, 24(1): 22-27 [DOI: 10.13604/j.cnki.46-1064/r.2024.01.05])
- Wang X and Zhu Z G. 2023. Context understanding in computer vision: A survey. *Computer Vision and Image Understanding*, 229: 103646 [DOI: 10.1016/j.cviu.2023.103646]
- Xiang S Y, Sun X and Wu Z D. 2020. Epidemic situation and control progress of plague in China. *China Tropical Medicine*, 20(5): 486-490 (向锁玉, 孙希, 吴忠道. 2020. 中国鼠疫的疫情及防治进展. *中国热带医学*, 20(05): 486-490 [DOI: 10.13604/j.cnki.46-1064/r.2020.05.20])
- Xu Z Y, Shen Z F, Li Y, Li J L, Wang H Y, Li S, Jiao S H and Li L L. 2022. Detection of water conservancy facilities in large-format image combining E-YOLO algorithm and NDWI constraint. *National Remote Sensing Bulletin*, 26(10): 2083-2093 (许泽宇, 沈占锋, 李杨, 李均力, 王浩宇, 李硕, 焦淑慧, 李苓苓. 2022. 结合E-YOLO和水体指数约束的大面幅影像水利设施检测. *遥感学报*, 26(10): 2083-2093 [DOI: 10.11834/jrs.20200124])
- Yuan X, Yang L S, Li H R, Wang L and Wei B G. 2022. Landscape pattern changes of *Meriones unguiculatus* plague focus in Inner Mongolia from 2000 to 2018. *Geographical Research*, 41(3): 867-879 (袁星, 杨林生, 李海蓉, 王利, 韦炳干. 2022. 2000—2018年内蒙古长爪沙鼠疫源地地表景观特征及变化. *地理研究*, 41(03): 867-879 [DOI: 10.11821/dlyj020210128])
- Zeng Z W, Li K, Guo H, Zeng Y L and Feng Q L. 2025. Research advances and challenges in animal remote sensing and telemetry. *National Remote Sensing Bulletin*, 29(10): 2859-2890 (曾志伟, 李可, 郭浩, 曾也鲁, 冯权洸. 2025. 动物遥感与遥测的研究进展与挑战. *遥感学报*, 29(10): 2859-2890 [DOI: 10.11834/jrs.20254437])
- Zhang J Q, Lei J, Xie W Y, Fang Z M, Li Y S and Du Q. 2023. SuperYOLO: Super resolution assisted object detection in multimodal remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 1-15 [DOI: 10.1109/TGRS.2023.3258666]
- Zhang L, Guo C, Xiao Y H and Xiang Z F. 2019. Den characteristics and their ecological significance in Himalayan marmots (*Marmota himalayana*). *Aata Theriologica Sinica*, 39(3): 258-265 (张龙, 郭程, 肖燕宏, 向左甫. 2019. 喜马拉雅旱獭的洞穴特征及其生态意义. *兽类学报*, 39(3): 258-265 [DOI: 10.16829/j.slxb.150218])
- Zhang M, Li J, Ding R L, Cheng H T and Shen J. 2020. Remote Sensing Image Object Detection Technology Based on Improved YOLO-V2 Algorithm. *Computer Science*, 47(6A): 176-180 (张曼, 李杰, 丁荣莉, 成昊天, 沈霁. 2020. 基于改进YOLO-V2算法的遥感图像目标检测技术研究. *计算机科学*, 47(S1): 176-180 [DOI: 10.11896/JsJkx.191100206])
- Zhang Y, Ye M, Zhu G Y, Liu Y, Guo P Y and Yan J H. 2024. FFCA-YOLO for Small Object Detection in Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 1-15 [DOI: 10.1109/TGRS.2024.3363057]
- Zhao Y, Lv W Y, Xu S L, Wei J M, Wang G Z, Dang Q Q, Liu Y and Chen J. 2024. DETRs Beat YOLOs on Real-time Object Detection//Proceedings of the IEEE/CVF Conference on computer vision and pattern recognition. Seattle: IEEE: 16965-16974 [DOI: 10.1109/CVPR52733.2024.01605]
- Zhu X K, Lyu S C, Wang X and Zhao Q. 2021. TPH-YOLOv5: Improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE: 2778-2788 [DOI: 10.1109/ICCVW54120.2021.00312]

Drone-based remote sensing identification of himalayan marmot holes

integrating habitat information

REN Hongyan¹, HUANG Kun^{1,2}, ZHAXI³

1. State Key Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China;

2. College of Resources and Environment, University of Chinese Academy of Sciences, Beijing 100049, China;

3. Xizang Autonomous Region Key Laboratory of Infectious Disease Control and Prevention, Xizang Autonomous Region Center for Disease Control and Prevention, Lhasa 850001, China

Abstract: Objective The application of drone imagery combined with deep learning technology has become a crucial approach for identifying Himalayan marmots and monitoring their activity patterns at large spatial scales. Within this workflow, the accurate identification of marmot holes is essential because holes provide a stable spatial proxy for the presence and density of animals. However, current methods are still constrained in practice. Owing to uneven terrain, stones around or above burrow entrances, and soil mounds and other ground objects that partially or completely obstruct openings, a considerable proportion of marmot holes are missed during detection. Consequently, the accuracy and robustness of existing burrow-identification techniques remain insufficient for reliable use in plague-related surveillance. Method This study focuses on several typical natural plague foci in the Xizang region. We carried out detailed ground surveys of marmot holes, recording entrance locations, dimensions and associated habitat characteristics. In parallel, UAV remote-sensing campaigns were conducted to obtain high-resolution aerial imagery over the same sites. Based on these observations, we constructed a UAV image dataset that incorporates both marmot burrow entrances and surrounding habitat elements such as stones patches and soil mounds formed by excavation. On this basis, we designed a data-annotation strategy that explicitly integrates habitat information into the labeled objects. Five representative object detection models—YOLOv8, YOLO11, YOLO13, RT-DETR and RF-DETR—were then trained and evaluated under two settings: a traditional annotation method using only the visible burrow entrance, and the proposed habitat-integrated annotation strategy. By systematically comparing results from these two strategies, we assessed the effectiveness of incorporating habitat information into the annotation process. Result Under the traditional annotation method, the accuracy rates for detecting marmot holes achieved by the five models were 93.0% (YOLOv8), 91.6% (YOLO11), 85.5% (YOLO13), 76.5% (RT-DETR), and 83.0% (RF-DETR). When the habitat-integrated annotation strategy was adopted, the performance of most models improved. All models showed higher detection accuracy except for YOLOv8, whose accuracy decreased slightly by 0.2 percentage points. The accuracy gains were 2.2 percentage points for YOLO11, 9.0 percentage points for YOLO13, 16.7 percentage points for RT-DETR and 6.5 percentage points for RF-DETR. The combination of RT-DETR with the habitat-integrated strategy produced the largest improvement, with an increase of about 17%, while the system integrating YOLO11 with the habitat-integrated strategy achieved the best overall performance. Conclusion These results show that an annotation strategy integrating habitat information can effectively reduce the risk of missing marmot holes caused by stones cover, soil mounds and other forms of occlusion that limit traditional annotation methods. By providing richer contextual cues around the entrances, this strategy improves the accuracy and reliability of drone-based identification of Himalayan marmot holes. The proposed annotation framework enhances UAV-based burrow detection, enriches the application of unmanned aerial vehicles for investigating plague focuses associated with Himalayan marmots and has important implications for monitoring and controlling marmot-borne plague across the Qinghai – Tibet Plateau.

Key words: unmanned aerial vehicles, deep learning, data annotation strategy, habitat information, Himalayan marmot holes, plague surveillance

Supported by Key Research and Development Program in Xizang Autonomous Region (No. XZ202401ZY0071), Second Qinghai-Tibet Plateau Scientific Expedition and Research (2019QZKK0607), Open bidding for selecting the best candidates Program in Xizang Autonomous Region (No. XZ202403ZY0015)