

# 面向应急救援的无人机多模态数据知识图谱构建 与智能决策系统

董思屏, 钮芮楠, 刘轩, 朱亚婷, 郑庆阳, 魏青

北方工业大学, 北京 100043

DOI:10.61369/ME.2025050031

**摘 要 :** 为破解传统洪灾监测“信息滞后、语义贫乏、数据孤岛”三大瓶颈, 本文提出“图像驱动-知识图谱赋能”框架 (Image-KG4Flood)。首先, 利用无人机与社交媒体多模态图像, 基于 PyTorch/OpenCV 构建分钟级在线学习管线, 将遥感周期由小时级压缩至 5-10 分钟; 其次, 以 YOLOv5 / Faster R-CNN 联合检测“人-车-房-船-树”5 类目标并估算洪水覆盖度, 构建覆盖 0%-90% 洪水梯度的 1 255 目标数据集; 再次, 设计 Neo4j 时空知识图谱统一水利 IoT、交通路网、气象预报等多源异构数据, 提出“规则逻辑特征+余弦相似度”的图嵌入方法, 实现 A-E 五级智能预警与“受困人员-最近安全点-可用救援艇”可解释决策路径。实验表明: 系统在 15% 覆盖度/3 目标场景下 0.95 以上相似度输出 A 级预警, 70% 覆盖度场景准确触发 E 级预警及大规模疏散建议, 单次响应时间 < 5 s。本研究不仅为洪灾应急提供了可复制、可推广的 AI+KG 技术范式, 也为台风、山火等极端气候事件的智能化响应提供方法学借鉴。

**关 键 词 :** 知识图谱; 目标检测; 洪水预警; 图嵌入; YOLOv5; Neo4j; 多模态融合

## Construction of a UAV Multimodal Data Knowledge Graph and Intelligent Decision-Making System for Emergency Rescue

Dong Siping, Niu Ruinan, Liu Xuan, Zhu Yating, Zheng Qingyang, Wei Qing

North China University of Technology, Beijing 100043

**Abstract :** To overcome the three major bottlenecks of traditional flood monitoring, namely "information lag, semantic poverty, and data silos," this paper proposes an "Image-Driven-Knowledge Graph Empowerment" framework (Image-KG4Flood). Firstly, leveraging multimodal images from unmanned aerial vehicles (UAVs) and social media, a minute-level online learning pipeline is constructed based on PyTorch/OpenCV, compressing the remote sensing cycle from hours to 5-10 minutes. Secondly, using YOLOv5/Faster R-CNN for joint detection of five target categories ("people-vehicles-houses-boats-trees") and estimating flood coverage, a dataset of 1,255 targets covering a flood gradient of 0%-90% is constructed. Thirdly, a Neo4j spatiotemporal knowledge graph is designed to unify multi-source heterogeneous data from water conservancy IoT, transportation networks, and weather forecasts. A graph embedding method combining "rule logic features + cosine similarity" is proposed to achieve five-level (A-E) intelligent early warnings and interpretable decision paths for "trapped individuals-nearest safe points-available rescue boats." Experiments show that the system outputs Level A warnings with over 0.95 similarity in scenarios with 15% coverage/3 targets, accurately triggers Level E warnings and large-scale evacuation recommendations in 70% coverage scenarios, and achieves a single response time of <5 seconds. This study not only provides a replicable and scalable AI+KG technical paradigm for flood emergency response but also offers methodological insights for intelligent responses to extreme climate events such as typhoons and wildfires.

**Keywords :** knowledge graph; target detection; flood warning; graph embedding; YOLOv5; Neo4j; multimodal fusion

### 一、研究背景

过去十年, 全球极端气候事件呈指数级增长, 洪涝灾害成为最具破坏力的自然灾害之一。据《中国水旱灾害公报 (2023)》,

2023 年我国洪灾直接经济损失达 1 842 亿元, 受灾人口 5 436 万。传统以遥感-统计模型为核心的洪灾监测与决策支持系统, 存在三点瓶颈: ① 信息滞后, 卫星重访周期与云雨天气常导致关键数据缺失; ② 语义贫乏, 像素级影像难以直接支撑应急指挥所

需的“谁-在哪里-需要什么”三元组决策；③ 数据孤岛，水利、交通、民政、社交媒体等多源异构数据缺乏统一建模框架，导致“数据海量、知识稀缺”。计算机视觉与知识图谱技术的交叉融合，为破解上述瓶颈提供了新思路：一方面，深度学习模型可从社交媒体、无人机、监控视频中实时提取受灾实体与情景；另一方面，知识图谱以图结构统一表示实体、关系与时空动态，支撑复杂推理与决策。然而，现有研究仍停留在“图-文”双模态对齐层面，缺乏针对洪灾场景高动态、高噪声、高时效特点的图像-知识图谱深度融合范式，亟需构建面向应急指挥的端到端框架。

## 二、研究意义

本研究提出“图像驱动-知识图谱赋能”(Image-KG4Flood)框架：利用 Python 生态(PyTorch、OpenCV)完成图像实体识别与关系抽取；基于 Neo4j 构建可扩展的时空知识图谱；面向抗洪救灾场景，设计图谱查询与推理接口，实现灾情感知、资源调度与影响评估一体化。该框架的创新价值体现在三方面：一是“分钟级”灾情更新，将社交媒体与无人机实时视频流接入在线学习管线，把传统小时级遥感周期压缩至 5-10 分钟，显著提升预警时效；二是“语义级”决策支持，通过将检测到的实体(人、车、堤坝)与图谱中的领域知识(脆弱性指数、救援资源分布)进行对齐与推理，自动生成“受困人员-最近安全点-可用救援艇”三元组路径，为指挥员提供可解释的行动方案；三是“开放型”数据生态，以图模式统一水利 IoT 水文时序、交通路网、气象预报等多源异构数据，打破部门壁垒，实现跨域知识共享。最终，本研究不仅为洪灾应急管理提供一套可复制、可推广的 AI+KG 技术范式，也为其他极端气候事件(台风、山火)的智能化响应提供方法学借鉴。<sup>[1][2]</sup>

## 三、文献综述

洪灾场景下的图像理解任务可分为受灾区域分割、受灾对象检测与情景识别三类。

① 区域分割：早期研究依赖多光谱遥感指数(NDWI、MNDWI)阈值法，易受混合像元影响。2018 年，Xu et al. 提出 FloodNet，首次将 U-Net 引入高分二号影像水体提取，IoU 达 0.91；随后 TransUNet、Swin-Unet 通过 Transformer 增强全局上下文，进一步提升精度。

② 对象检测：无人机与街景图像分辨率提升至厘米级，使检测“被困人员、车辆、船只、救生艇”成为可能。2021 年，Guo et al. 发布 FloodDrone 数据集，含 21 337 张无人机图像与 7 类目标；YOLOv5 在该数据集 mAP@0.5 为 0.745。最近，Li et al. 引入 CLIP 文本先验，实现零样本洪灾物体检测。

③ 情景识别：为回答“发生了什么”而非“有什么”，Chen et al. 提出 FloodSituationGraph，将图像解析为<主体，行为，客体>三元组，准确率 82.3%。但现有工作多停留在视觉层面，

缺乏与外部知识库的深度耦合。

## 四、基于深度学习和图嵌入的洪水灾害分级预警系统研究与实现

### (一) 洪水场景目标检测数据集的构建

#### 1. 数据集构建的背景与目标

现有洪水相关公开数据集存在样本规模场景单一，未关联洪水覆盖程度的缺陷，无法满足“目标-覆盖度”协同检测的需求。本研究针对“房屋(财产损失)、人(人员安全)、树(地形标识)、车辆(财产损失)、船(水上救援)”5 类核心目标，构建覆盖 0%-90% 洪水覆盖度的数据集，为 YOLOv5 模型训练提供支撑，数据集制作流程如图 1 所示。



图1 数据集制作的主要流程

#### 2. 原始数据集采集与预处理

##### (1) 数据采集与筛选

通过互联网公开图像资源平台(如百度图片、Google Images 等)以“洪水淹没”“洪涝灾害”“城市内涝”等为关键词进行定向检索，通过分辨率 $\geq 220 \times 220$ ，目标遮挡率 $<70\%$ ，含明显洪水特征三重筛选，最终采集 296 张高质量图像。

##### (2) 数据预处理与分类

遵循“保持原貌”原则，未额外进行像素级修改，最大程度保留原始洪水场景的真实性与目标特征的完整性。将数据集按功能划分为 images(存储图片文件)和 labels(存储标注标签文件)两大文件夹，且均进一步细分为 train(训练集，274 张)、val(验证集，17 张)、test(测试集，5 张)子文件夹

#### 3. 目标标注规范与实施

##### (1) 标注工具与规则

选用 Labellmg 工具标注，标签格式为“flood coverage X%-类别”(如“flood coverage 50%-people”洪水覆盖度 50% 的人员)。围绕 5 类核心目标与 0%-90% 洪水覆盖度(10% 间隔)，设计 45 种差异化标签。标注过程如图 2 所示。



图2 Labellmg 标注过程

(2) 标注文件格式

为适配 YOLOv5 算法输入要求,采用 YOLO 模式生成的 txt 文件来承载标注信息,且标注数据与图像文件一一对应,文件存储目录如图3所示。




图3 LabelImg 标注生成 txt 文件存储目录

4. 数据集统计与质量评估

最终标注目标总计1255个,各类分布如表4所示,目标总体分布较为均衡,涵盖了各类关键物体,其中数据集中“树”类样本最多,因树木为洪水场景中“淹没范围边界”的关键标识;“船”类样本最少,因水上洪水场景样本获取难度较高,但仍可满足模型对水上目标的识别需求。

表4 洪水勘测数据集各类样本分布表

	人	车	树	房	船
训练集	296	225	364	174	49
验证集	31	17	25	8	7
测试集	35	19	1	1	3
总计	362	261	390	183	59

(二) 洪水灾害目标检测算法研究

1. 核心算法原理

(1) Faster R-CNN 算法

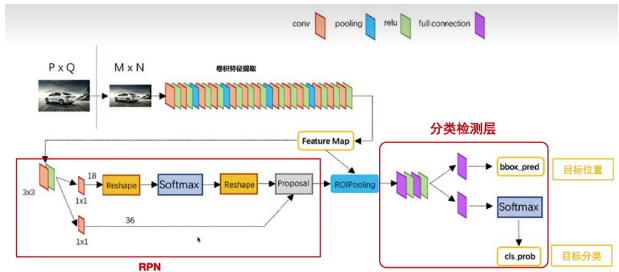


图5 Faster r-cnn 算法流程架构图

Faster R-CNN 是一种经典的两阶段目标检测算法,其核心创新在于引入了区域提议网络 (Region Proposal Network, RPN), 实现了端到端的训练,解决了传统 R-CNN 系列候选框生成满的问题。算法流程如图5所示。Faster R-CNN 经过 Conv layers 进行特征提取、RPN 生成检测框、Roi Pooling 和 Classification 对候选检测框进行分类,并微调候选框坐标输出结果。其损失函数为 RPN 损失与分类回归损失的加权和,公式如下

$$L(p_i, t_i) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*)$$

(2) YOLOv5 算法

YOLOv5 采用单阶段检测架构,将目标检测任务视为回归问题,在单个网络中同时完成目标定位和分类。如图6所示,其网络结构基于 CSPDarknet53 主干网络,结合路径聚合网络

(PANet) 实现多尺度特征融合。Backbone 采用 CSPDarknet53 作为特征提取主干网络,通过跨阶段局部连接增强梯度流,在保持精度的同时显著降低计算复杂度;Neck 使用 PANet 结构实现自上而下和自下而上的多尺度特征融合,增强对不同尺度目标的检测能力;Head 输出层采用锚点框机制,在三个不同尺度的特征图上进行预测,分别负责大、中、小目标的检测。<sup>[3][4]</sup>




图6 yolo 的网络结构

yolo 损失函数:

$$\begin{aligned} \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{obj} \left[ (x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right] \\ + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{obj} \left[ (\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2 \right] \\ + \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{obj} (C_i - \hat{C}_i)^2 \\ + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{noobj} (C_i - \hat{C}_i)^2 \\ + \sum_{i=0}^{S^2} \mathbb{1}_i^{obj} \sum_{c \in classes} (p_i(c) - \hat{p}_i(c))^2 \end{aligned}$$

损失函数也是多个不同种类损失的加权和,也图像识别问题最终转换成了回归问题,而且是端到端的,只要构建好正确的标签直接训练就训练网络了。

2. 算法实验与性能对比

(1) 实验设置与结果

1) Faster R-CNN 图像处理

基于 PyTorch 框架构建了一套完整的图像分析系统。选用 COCO 数据集预训练模型,在精度和速度间取得良好平衡,针对高分辨率图像处理,设计自适应压缩模块:当图像超过2MB 阈值时,自动将最长边缩放至1024 像素,显著降低显存消耗,提升系统鲁棒性。

核心推理阶段,标准化后的图像输入模型,获得带置信度的检测框,采用0.5 置信度阈值滤除不可靠预测。进一步基于几何规则进行空间关系推理:通过计算边界框中心点相对位置判定方位关系;通过重叠面积判断包含关系;通过欧氏距离与图像尺寸的比值判定邻近程度。

最终,系统将检测结果可视化标注于图像上,并自动生成包含检测结果和空间关系分析的 word 报告,如图7所示。





物体数量：21<sup>[4]</sup>

1. bus - far\_from - car<sup>[4]</sup>
2. car - far\_from - bus<sup>[4]</sup>
3. bus - left\_of - car<sup>[4]</sup>
4. car - right\_of - bus<sup>[4]</sup>
5. bus - left\_of - person<sup>[4]</sup>
6. person - right\_of - bus<sup>[4]</sup>
7. bus - contains - person<sup>[4]</sup>
8. person - inside - bus<sup>[4]</sup>
9. car - far\_from - person<sup>[4]</sup>
10. car - right\_of - person<sup>[4]</sup>

图7 程序自动生成的 word 报告例图

## 2) 基于 YOLOv5 的目标检测系统

本系统基于 YOLOv5 构建，处理流程包含四个核心阶段：系统初始化、数据预处理、模型推理与后处理。最终输出可视化检测图像、结构化 Excel 数据及 Word 汇总报告。

系统首先验证输入路径（支持单张图像或整个目录），无效路径将报错终止。自动适配 GPU/CPU 硬件。通过 LoadImages 类进行标准化预处理：保持原始宽高比进行等比例缩放；将颜色通道由 BGR 转换为 RGB；将图像数据转换为 float32 类型的 Tensor，并进行归一化处理至 [0.0, 1.0] 范围，以满足模型输入要求。

核心推理在 `detect\_image()` 函数中完成：将预处理后的 Tensor 输入 YOLOv5 模型，通过置信度阈值和交并比（IoU）阈值过滤低质量预测框，去除冗余检测结果。最后将预测框坐标映射回原始图像尺寸，并将检测结果（类别、置信度、坐标）解析存储至结构化字典中。运行结果如图8所示。



检测的目标<sup>[4]</sup>

目标类别 <sup>[4]</sup>	置信度 <sup>[4]</sup>	位置 <sup>[4]</sup>	坐标 <sup>[4]</sup>
flood coverage 10%-car <sup>[4]</sup>	0.25 <sup>[4]</sup>	左上 - 右下 <sup>[4]</sup>	1139.244 - 1919.713 <sup>[4]</sup>
flood coverage 10%-car <sup>[4]</sup>	0.30 <sup>[4]</sup>	左上 - 右下 <sup>[4]</sup>	0.147 - 597.615 <sup>[4]</sup>
flood coverage 20%-car <sup>[4]</sup>	0.31 <sup>[4]</sup>	左上 - 右下 <sup>[4]</sup>	0.167 - 592.560 <sup>[4]</sup>
flood coverage 50%-people <sup>[4]</sup>	0.45 <sup>[4]</sup>	左上 - 右下 <sup>[4]</sup>	769.224 - 1074.712 <sup>[4]</sup>

图8 程序自动生成的 word 报告例图

## (2) 实验结果分析

实验结果显示：Faster R-CNN 的平均精度普遍高于 YOLO，尤其在小目标检测中更具优势，如人物在车内也能够很好的识别，所以更适合高精度应用场合；YOLO 的检测速度远超 Faster R-CNN，对固定组合关系经过训练也能很好的识别，但是比起 faster r-cnn 的精度还是有一定的差距，但是其训练和使用相对简易，通过预先训练好标注好的训练图和淹没百分比可以迅速判断洪水的实时淹没情况。

## (三) 基于图嵌入的洪水分级预警系统原理

### 1. 系统架构

系统以 Neo4j 图数据库为核心，接收 YOLOv5 或 Faster R-CNN 目标检测算法输出的结构化结果（Excel 格式），通过数据解析、图谱构建、图嵌入计算与相似度匹配，最终输出 A - E 五级预警及应急措施。流程图如图9所示。

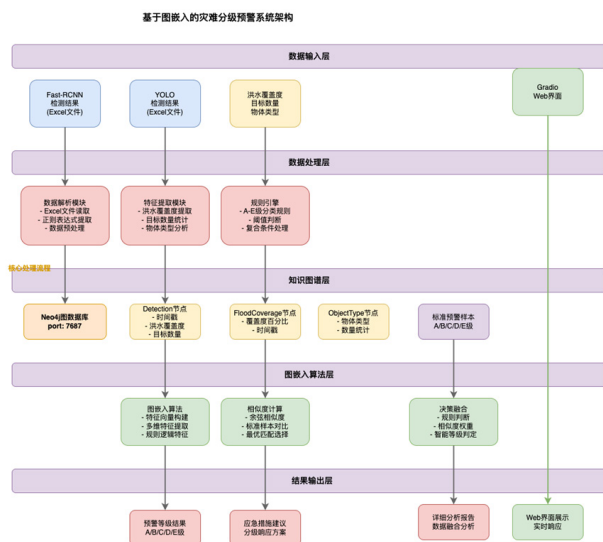


图9 系统整体架构图

### 2. 预警等级定义

预警等级分为 A 到 E 五个级别。A 级代表低风险，洪水覆盖度  $\leq 20\%$  且目标数量  $< 5$  个；B 级为较低风险，洪水覆盖度  $\leq 20\%$  但目标数量  $\geq 5$  个；C 级属中等风险，洪水覆盖度在  $20\% - 40\%$  范围；D 级为较高风险，洪水覆盖度在  $40\% - 60\%$  范围；E 级属高风险，洪水覆盖度  $> 60\%$ 。

### 3. 知识图谱构建

在 Neo4j 中设计多层次节点类型体系。Detection 节点作为主节点，承载着每次检测的核心信息，包括精确的时间戳、提取的洪水覆盖度数值和统计的目标数量。FloodCoverage 节点专门存储洪水覆盖度相关数据，不仅包含百分比数值，还记录了对应的的时间戳。TargetCount 节点专注于目标数量信息的存储。ObjectType 节点不仅存储检测到的物体类型，还记录每种类型的具体数量。

图结构中的关系设计体现了数据间的逻辑关联。如图10所示 Detection 节点通过 HAS\_FLOOD\_COVERAGE 关系与 FloodCoverage 节点建立连接，明确表达了检测结果与洪水覆盖度之间的从属关系。HAS\_TARGET\_COUNT 关系则连接

Detection节点和 TargetCount节点，建立了检测结果与目标计数的关联。DETECTED关系连接 Detection节点和各个 ObjectType节点，形成了一对多的关系结构，完整记录了单次检测中发现的所有物体类型。

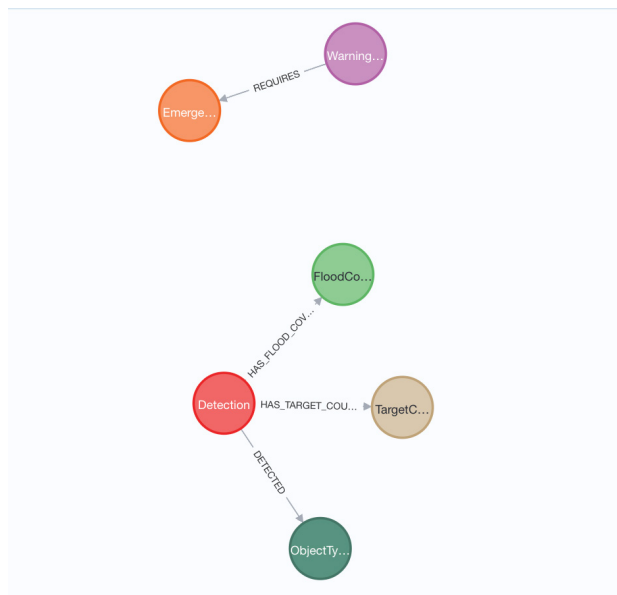


图 10 Neo4j 知识图谱结构示例

#### 4. 图嵌入与相似度计算

### (1) 图嵌入向量设计

图嵌入算法将复杂的图结构转化为8维的数值向量。基础特征维度包括归一化的洪水覆盖度和目标数量,确保了不同量级数据的可比性。

规则逻辑特征的引入是算法的创新之处。针对 A 级和 B 级预警的区分难点, 我们设计了专门的边界特征。当洪水覆盖度不超过 20% 时, 目标数量是否达到 5 个成为关键的判别因素。这种设计将专业的预警规则直接嵌入到了算法特征中, 提高了分类的准确性。

## (2) 相似度匹配

采用余弦相似度算法,有效衡量高维向量间的相似程度,不受向量长度影响。新的检测数据会与预先建立的五个标准样本逐一计算相似度,形成相似度向量。系统选择相似度最高的样本对应的预警等级作为最终判定结果。巧妙结合了规则判断的确定性和机器学习方法的灵活性,实现了智能化的预警等级判定。

#### （四）系统实现与测试分析

## 1. 开发环境与依赖库

在本地计算机上部署完整的开发和测试环境。Neo4j图数据库作为核心存储组件，运行在默认的7687端口，Python运行环境选择3.8版本，确保与所有依赖库的兼容性。

系统依赖库的选择经过仔细考虑。pandas库负责 Excel 文件的读取和数据处理，gradio框架提供了快速构建 Web界面的能力，py2neo库作为 Neo4j的 Python客户端，提供了完整的图数据库操作接口。scikit-learn库则为相似度计算提供了成熟的算法实现。

## 2.Web界面与数据处理流程

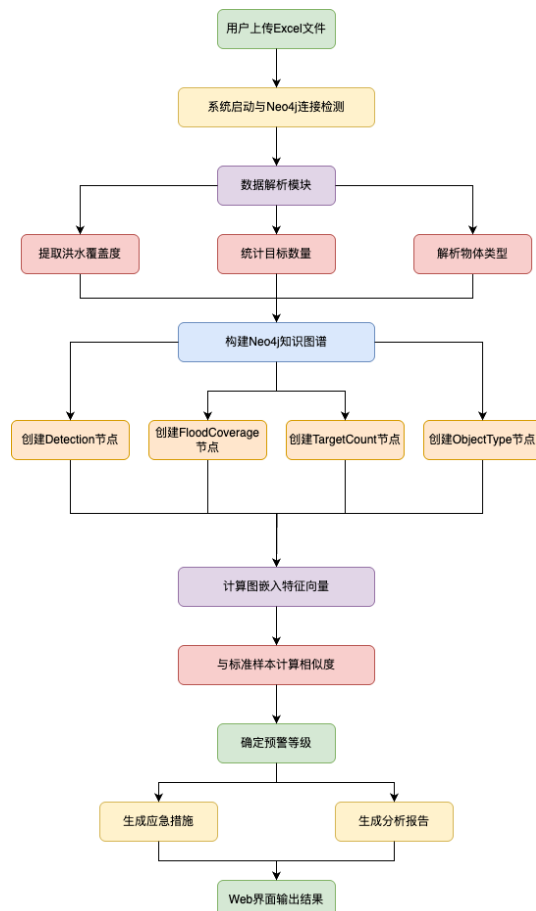


图 11 系统流程图

系统流程遵循“用户交互 - 数据解析 - 图谱构建 - 预警输出”逻辑, 如图11所示: 用户通过 Web 界面上上传 Excel 文件, 系统自动检测 Neo4j 连接状态, 解析数据后构建图谱, 生成图嵌入向量并匹配预警等级, 最终输出预警结果、应急措施与详细报告。Web 界面设计简洁, 支持“拖放上传”与“格式说明”, 降低用户操作门槛, 界面如图12所示。



图 12: Web 界面截图

### 3.测试结果与性能

系统测试使用包含不同场景的数据集。测试数据涵盖各种洪水覆盖度和目标数量组合。结果显示系统能够准确识别不同风险等级。

洪水覆盖度15%、检测目标数3个的场景中,系统正确判定为A级预警。相似度计算显示与A级标准样本相似度达0.95以上。

对应急措施包括居民准备雨衣雨伞、减少外出、救援方推砂沙袋拦水。

洪水覆盖度18%但检测目标数增至7个时，系统调整为B级预警。这体现了系统对复合风险因素的敏感性。洪水覆盖度较低，但受影响人员增加提升了整体风险等级。

洪水覆盖度30%被正确识别为C级预警。系统生成的应急措施更全面，包括居民准备漂浮物、救援方准备抽水器和救生衣等设备。

洪水覆盖度达70%时，系统给出E级高风险预警。应急措施涵盖大规模疏散、向高处转移、加固河堤等关键行动。快速准确判定对实际救援工作具有重要意义。




图 13: Neo4j 数据库中的实际数据图




图 14: 系统性能测试结果

#### 4. 系统核心优势与研究价值

##### （1）系统设计优势

Web界面设计简洁，三个输出区域分别显示预警结果、应急措施和详细分析报告，信息层次清晰。方便用户快速获取关键

信息。

系统实时性表现良好。文件上传到结果输出通常在几秒内完成。快速响应能力对应急场景具有重要价值。灾情发生时，每秒钟都可能关系生命安全。

模块化架构使添加新检测算法数据源相对简单。预警规则可根据实际需求调整优化。灵活性确保系统长期适用性。

本研究验证了图嵌入技术在灾难预警领域的应用潜力。不同来源检测数据整合到统一知识图谱中，提供更准确风险评估。相似度计算方法有效结合规则判断和数据驱动方法，实现智能化预警等级判定。

##### （2）研究应用价值

本研究首次将图嵌入技术与 Neo4j 知识图谱结合，实现 Faster R-CNN/YOLOv5 多源检测数据的结构化整合，解决传统系统“数据碎片化、风险评估模糊”的问题，为灾难预警领域提供可复用的“数据-算法-系统”技术框架；

采用“规则逻辑特征+余弦相似度计算”的混合判定方法——既通过规则特征确保预警标准的专业性，又通过数据驱动的相似度匹配提升复杂场景适应性，实现“精准性+灵活性”的双重保障，为后续其他灾害（如泥石流、地震次生灾害）预警系统设计提供参考。

## 五、 结论与展望

##### （一）研究结论

本研究通过对无人机技术在洪涝应急响应中的实际应用，并搭建了“图像驱动-知识图谱赋能”(Image-KG4Flood)框架：结合使用多模态数据处理和知识图谱构建技术，开展了针对洪涝灾情快速分析以及相关应急措施的研究，取得以下关键结论：

##### （二）多模态数据采集

运用无人机搭载多类型传感器设备，实现在洪涝应急救援现场对灾害图象等多模态数据的高效、立体化采集，为灾情分析提供全面、实时的数据基础，并为灾情应急决策提供了坚实的数据支撑。

##### （三）多模态数据处理

本研究使用 Python生态(PyTorch、OpenCV)技术，对灾害图片进行自动化快速信息处理；通过 Labellmg 高效完成图像标注，与作为目标检测工具的 YOLOv5模型相配合，并利用 Fast-RCNN和 YOLO算法精准识别检测受灾区域中的目标信息（如道路淹没区域、受困人员等关键要素）、提取洪水淹没范围及其覆盖度，并还原关键地物之间的位置关系，最后生成一目了然的检测结果图，实现灾情关键信息的智能化处理，大幅提升了信息提取的处理效率，增强了灾情评估的客观性与准确性。<sup>[5]</sup>

##### （四）知识图谱应用

借助 Neo4j图数据库，利用 pandas库对前期处理得出的结构化灾情数据（如洪水覆盖度、目标数量、物体类型）生成的 Excel结果表的进行读取与处理，构建 Neo4j知识图谱，依托图谱的查询与推理接口，将分析结果与系统初始化的标准样本的相似度进



行计算，从而实现智能输出灾害预警等级（从 A 到 E 共五个等级）以及应急措施的智能匹配与分析报告的输出，为指挥决策提供科学、直观的处理依据，有效推动应急响应从经验化转向为更加精确的数据化。

**（五）研究的局限性**

尽管本研究取得了一定成果，但在实际应用的过程中仍然发现若干局限性，具体包括：

**（六）目标识别能力有限**

当前无法识别出场景中除目标信息、洪水覆盖度以及相关位置关系以外的其他信息，此外，在高密度目标场景下，有时无法识别出所有目标，识别完整性以及高精度性有待提高。

**（七）洪水覆盖度测算精度不足**

经过多模态数据处理后所获取的洪水覆盖度精确度低，无法输出分度值在 10% 以下的值，限制了对轻微淹没情形的判断能力。

**（八）知识图谱应急措施生成的实用性存在不足**

知识图谱构建后得到的应急措施还不够具体，未能实现与地方应急预案的深度融合，不能大范围使用。

上述局限性在一定程度上影响了本研究结论的普适性与可靠性，也为后续研究指明了改进方向，未来需通过算法优化、多种信息融合与真实场景验证等手段进一步加以完善。

**（九）研究展望**

基于本研究的结果与发现，我们初步构建了一个利用多模态数据进行洪水灾害应急分析的技术框架。然而，这仅仅是利用智能技术进行灾害救援的开始，未来的研究还有更广阔的发展空间，可以从对以下几个关键方面深入展开，推动该技术在多维度的发展。

**（十）在数据采集的维度上**

应解决数据采集的局限问题。未来，在采集多模式数据时，可以极大地增加传感器类型与数据源，引入视频、音频、热成像、无人机摄影等的传感器网络，使得构成一个天地一体化的

立体感知的体系。视频数据能提供洪水流速、流向的动态直观信息；音频数据可用于识别求救呼叫、洪水冲击建筑物的异常声响，为判断灾情严重程度提供辅助线索；同时部署于救灾现场的无人机群，能够深入危险区域并且传回实时的高清影像。通过融合这些数据，我们可以实现高度逼真地重现灾害场景，为高层决策提供更深度信息。

**（十一）在数据处理的维度上，实现从“识别”到“精确量化”的跨越**

目前的技术只能较好的识别出洪水覆盖度，但在覆盖深度、流速流量、淹没体积等关键参数的处理上还有较大提升空间。随着深度学习的领域发展，未来研究需致力于提高数据处理的自动化水平与准确性，这依赖于新的人工智能算法的突破，特别是深度学习与物理模型相结合的探索，可尝试更新的如 YOLO11 或基于 Transformer 的一些模型，使得在识别精度上和速度上实现更大的突破。<sup>[6]</sup>

**（十二）在应用场景的维度上，应从“单一灾种”拓展到“全灾种应急”**

本研究聚焦于洪水灾害，但其核心技术——多模态数据处理、构建知识图谱具有较强的迁移性与通用性。未来研究可以打破技术壁垒，将成熟的解决方案向地震、山体滑坡、森林火灾、台风等各类自然灾害延伸。通过各种跨灾种的技术拓展与适配，最终目标是构建一个“智慧大应急”平台，实现从灾前预警、灾中响应到灾后恢复的全过程、多灾种智能化管理。

所有的研究将朝一个共同的方向努力：构建一个更智能、更全面、更精准的下一代自然灾害应急救援技术体系。这一体系能够依托强大的算法，在大量多模态数据中自动挖掘关键信息，生成最优的救援方案与资源调度策略；能够为现场指挥员、政府决策者乃至社会公众提供个性化、可视化的决策支持与预警信息，最终极大提升全社会的防灾减灾救灾能力，最大限度地保护人民的生命财产安全。<sup>[7]</sup>

参考文献

[1] 谭平, 刘惠娜, 韦昌法. 基于 BiLSTM-CRF 和 Neo4j 的脾胃病知识图谱构建 [J]. 科学技术与工程, 2025, 25(22): 9436-9444.  
[2] 马婷. 基于 Neo4j 图数据管理系统的清热类中成药知识图谱的建立及应用 [D]. 宁夏医科大学, 2025. DOI: 10.27258/d.cnki.gnxyc.2025.000332.  
[3] 史政一, 吕君可, 黄弘. 基于 Neo4j 的城市地下管道信息知识图谱构建研究 [J]. 中国安全生产科学技术, 2024, 20(06): 5-10.  
[4] 李宗柱, 宋绍剑, 李修华. 一种基于 YOLOv5 的农业害虫检测方法 [J]. 植物保护, 2025, 51(01): 111-122. DOI: 10.16688/j.zwbh.2024089.  
[5] 孙华宇. 基于深度学习电动车驾驶员头盔佩戴检测研究 [D]. 沈阳理工大学, 2023. DOI: 10.27323/d.cnki.gsgyc.2023.000530.  
[6] 蒋润康. 基于深度学习的电动车骑行人员头盔佩戴检测系统 [D]. 宁夏大学, 2022. DOI: 10.27257/d.cnki.gnxhc.2022.001825.  
[7] 翁云龙. 基于深度学习的水面漂浮物检测方法研究 [D]. 浙江科技大学, 2024. DOI: 10.27840/d.cnki.gzjkj.2024.000163.