

文章编号 1004-924X(2025)09-1446-10

基于知识图谱的红外目标部件识别

刘海毅, 李正周*, 李傲燃, 刘海涛
(重庆大学 微电子与通信工程学院, 重庆 401331)

摘要:针对目标自遮挡、视觉特征不明显、特征变化大等导致部件识别准确性降低难题,提出一种基于知识图谱的红外目标部件识别方法。采用先识别目标整体,再识别目标部件的两阶段识别策略。首先检测目标整体,将目标区域扩展到高分辨率增强信号细节信息,提升目标识别能力;然后,部件识别模型融入目标知识图谱,利用目标部件结构关系推理部件同现关系,融合部件关联性注意力提升部件识别性能,解决由于视觉特征不足带来的部件识别难题;针对部件自遮挡,提出基于自遮挡的学习率控制策略,增强模型对遮挡的学习性能和收敛性。最后,搭建了室内目标等效缩比模型验证系统,对在不同姿态与距离条件下的飞机进行测试,识别平均精度达到 92.2%。实验结果表明,所提方法识别目标部件能力更佳,显著提升了精度和召回率。

关键词:红外目标识别;知识图谱;整体识别;全局向量模型;注意力模块;学习率控制

中图分类号:TP391.4 **文献标识码:**A

doi:10. 37188/OPE. 20253309. 1446

CSTR:32169. 14. OPE. 20253309. 1446

Knowledge graph-based method for infrared target component recognition

LIU Haiyi, LI Zhengzhou*, LI Aoran, LIU Haitao

(School of Microelectronics and Communication Engineering, Chongqing University,
Chongqing 401331, China)

* Corresponding author, E-mail: lizhengzhou@cqu.edu.cn

Abstract: To address challenges in component recognition, such as self-occlusion, unclear visual features, and substantial feature variation due to distance, a novel infrared target component recognition method based on a knowledge graph is proposed. This method utilizes a whole-to-component prediction (WCP) strategy to sequentially recognize target components. Initially, the overall target is detected, followed by an expansion of the target region to high resolution to enhance signal details. Subsequently, a component-related attention module (CAM) integrated with the knowledge graph exploits structural relationships among parts to infer visible interconnections and employs attention mechanisms to improve recognition performance, thereby mitigating issues arising from ambiguous visual features. For components affected by self-occlusion, a Self-Occlusion Learning Rate Decay (SLD) control strategy, based on self-removal capability, is introduced to strengthen the model's capacity to learn from occlusions and facilitate convergence. Validation is conducted using an indoor target equivalence scaling system, employing room-

收稿日期:2025-02-13;修订日期:2025-03-25.

基金项目:国家自然科学基金资助项目(No. 61675036);十三五国防预研基金资助项目(No. 6140415020312)

based models across various orientations and distances, with aircraft tested under diverse conditions, achieving an average precision of 92.2%. Experimental results demonstrate that the proposed method surpasses existing approaches in component recognition accuracy and recall, markedly enhancing both precision and recall metrics.

Key words: infrared target recognition; knowledge graph; whole to component predict; attention module; self-occlusion learning rate decay

1 引言

红外图像中目标部件识别能够更精确地理解和分析其结构,有利于精准定姿和定位,在工业领域和军事应用中具有重要作用^[1]。目标部件识别可分为传统算法^[2]和深度学习^[3]两类方法。传统算法主要依赖于滑动窗口和方向梯度直方图特征识别目标部件^[4]。然而,该方法需要人工定义特征,对不同部件的特征适应性较差,难以满足实际应用的多样化需求。深度学习方法使用卷积神经网络自动学习更抽象、更高维的特征,具有强大的特征表达能力和泛化性。

蔡引娣^[5]等基于改进的YOLOv8提出了一种缺陷检测方法,显著提升了零件表面缺陷的检测准确率。蒋占军^[6]等使用GENet网络对低光照图像进行图像增强,提高了低光照目标的检测精度。宋宗莹等^[7]在相邻尺度特征图融合过程中加入坐标注意力机制,有效提高了部件的识别精度。蓝贵文等^[8]在YOLOv8n模型引入坐标注意力机制进行特征学习,提升了输电线路部件的识别精度。然而,现有部件识别算法往往忽略了目标的部件之间结构关系和语义关系,在目标出现自遮挡、成像模糊等情况时识别能力下降。知识图谱^[9]是一种以图结构表示的知识库,它用于描述实体、属性和它们之间的关系。知识图谱有助于知识推理,加深从整体到局部的联系,在信息整合、语义理解和关系分布等方面有着得天独厚的优势。Chen^[10]堆叠3个门控神经网络单元(Gated Recurrent Unit, GRU),通过迭代推理获得空间关系和语义特征。Xu等^[11]通过全局语义池构建先验知识库,但是从知识库提取的特征并不是很有效。有效快速地提取目标间的先验知识是推理的关键。研究表明,图卷积网络能快速提取不规则结构信息^[12],只需要几层就可有效提取非结构化信息。2017年,Fang等结合目标识

别与知识图谱^[13],成功验证了知识图谱在目标识别中的可行性。2018年,Jiang等将知识图谱应用于大规模的目标识别中^[14]。2019年,Xu等在大规模目标识别引入自适应全局推理^[15],并将知识图谱的关系网络与深度学习网络相结合,得到了基于知识图谱的大规模目标识别空间感知图关系网络^[16]。

随着ImageNet等大规模图像数据集的出现,目标识别等技术逐渐成熟^[17]。但是,由于数据集信息缺失以及识别方法等原因,目标部件识别问题尚未得到有效解决,尤其是低分辨小目标、目标自遮挡、视觉特征不明显、特征变化大等条件下目标部件的识别性能较差。针对该问题,本文提出了一种基于知识图谱的红外目标部件识别方法。该方法结合知识图谱的关系网络,通过部件之间关系推理,有效解决了目标自遮挡、成像模糊等条件下部件识别问题。该方法采用先识别目标整体,再识别目标部件的两阶段识别策略,利用基于单词表示的全局向量模型^[18](Global Vectors for Word Representation, GloVe)将部件信息映射为词向量,融入空间注意力模块,关联部件类别信息,计算部件相关联的经验向量和部件同现数图矩阵;利用经验向量和知识图矩阵构建经验关系图和融合特征图,提升部件识别性能。同时,充分考虑因目标姿态导致部件自遮挡的问题,在数据集中加入自遮挡/非遮挡标签表示部件出现状态,自适应调整学习率,减少因遮挡产生的误导特征对模型的影响。所提方法显著提升了精度和召回率,具有更强的目标识别能力。

2 原理

针对现有的深度学习网络模型在目标出现自遮挡、成像模糊等情况时识别能力下降,识别

召回率大幅下降,环境状态适应性较差等问题,本文提出了基于知识图谱的红外目标部件识别方法,如图1所示。该方法采用先识别目标整体,整体局部识别方法(Whole to Component Prediction, WCP)。首先检测目标整体,将目标区域扩展到高分辨率,进行锐化滤波等增强细节和边缘信息,以解决放大图像中存在模糊或细节不清晰问题,提升目标识别能力。之后,对目标识别后的高分辨率目标图像进行部件识别,部件识别模型融入目标知识图谱,利用目标部件结构关系推理部件同现关系,融合部件关联性注意力提升部

件识别性能,解决由于视觉特征不足带来的部件识别难题。值得注意的是,该方法在检测识别出整体目标后提升目标分辨率,以确保不同距离下目标部件的分辨率充足,有利于提升部件识别性能。

2.1 基于知识图谱的部件识别策略

图2为基于知识图谱的红外目标部件识别算法结构,其主要结构为Backbone,Head与Detect3个部分,输入为 640×640 的红外图像。该算法使用YOLOv8的Backbone,由Conv模块、C2f模块和快速空间金字塔池化(Spatial Pyramid Pooling Fast, SPPF)模块构成。Conv模块由卷积、批归一化(Batch Normalization, BN)和激活函数(Sigmoid Linear Unit, SiLU)拼接而成。C2f模块由两个Conv模块和Bottleneck结构拼接而成。在Conv模块和C2f模块的基础上,Head部分结合知识图谱中的同现关系(同时未被遮挡),增加了部件关联性注意力模块(Component-related Attention Module, CAM),用以通过推理目标部件之间关系来增强部件识别能力。

针对目标的部件框分布构建同现知识,利用知识图谱对目标特征进行图卷积操作,让目标特




图1 整体局部识别流程

Fig.1 Implementation process of whole to component prediction(WCP) method




图2 基于知识图谱的部件识别算法结构

Fig.2 Structure of knowledge graph-based component detection algorithm

征沿着知识图谱节点的边进行传播,最终得到融合了同现关系的目标增强特征。结合知识图谱与视觉特征,本文算法构建CAM统计目标某一侧的部件关联程度,利用知识图谱推理部件存在关系,提高部件识别的准确率,如图3所示。CAM利用类别标签的词嵌入向量和目标类别的关系矩阵构造关系图,增强识别同一侧中潜在的同现部件。CAM将同现关系融入到视觉特征中,提高了自遮挡、视觉特征不明显、特征变化等情况下的部件识别能力。利用部件之间的同现关系,该方法使用Glove模型在全局词与词同现计数上训练得到的词嵌入向量 $V \in \mathbf{R}^{n \times r}$,其中 n 表示类别数, r 表示维数。同现矩阵 $A \in \mathbf{R}^{n \times n}$ 表示在目标不同姿态下部件类别之间的同现概率。




图3 CAM结构

Fig. 3 Structure of CAM

如图4所示,飞机的左侧机翼、左侧尾翼与左侧垂翼具有同现关系,而右侧的尾翼则由于被遮挡而没有同现。图5为知识图谱推理流程。首先



图4 飞机姿态示例

Fig. 4 Example of aircraft attitude




图5 知识图谱推理流程

Fig. 5 Flow chart of knowledge graph inference

构造同现邻接矩阵。该有向同现关系图以单词嵌入向量 $V \in \mathbf{R}^{n \times r}$ 为节点,并利用非对称同现矩阵 $A \in \mathbf{R}^{n \times n}$ 对其进行初始化。给定一个标记的训练数据集,计算每个部件在所有图像中出现的次数:

$$A_p = \{A_1, A_2, A_3, \dots, A_n\}, \quad (1)$$

式中 $A_i (i \in \{1, 2, 3, \dots, n\})$ 表示部件 i 在整个数据集中出现的次数。

然后构建一个初始矩阵 $C = \mathbf{R}^{n \times n}$ 来计算任意两个部件出现的次数:

$$C = \begin{bmatrix} C_{11} & \dots & C_{1n} \\ \vdots & \ddots & \vdots \\ C_{n1} & \dots & C_{nn} \end{bmatrix}, \quad (2)$$

式中 C_{ij} 表示部件 i 和部件 j 同现的次数。具体而言,当部件 i 和部件 j 同时在某一图中未遮挡时, C_{ij} 和 C_{ji} 同时加1。为了建立不同部件之间的有向同现关系,通过计算它们的条件概率,构造一个非对称的同现矩阵 $A \in \mathbf{R}^{n \times n}$:

$$A = \begin{bmatrix} A_{11} & \dots & A_{1n} \\ \vdots & \ddots & \vdots \\ A_{n1} & \dots & A_{nn} \end{bmatrix}, \quad (3)$$

$$\begin{cases} A_{ij} = P(C_i | C_j) = C_{ij} / A_j \\ A_{ji} = P(C_j | C_i) = C_{ji} / A_i \end{cases}, \quad (4)$$

式中 A_{ij} 表示当部件 j 未被遮挡时,部件 i 也同时未被遮挡的概率。

本文采用图卷积网络(Graph Convolutional Network, GCN)来推理同现关系。GCN对节点特征沿着对应的边进行操作,并应用非线性函数

LeakyReLU^[19]来更新节点特征,推理公式为:

$$F^{(l+1)} = L(\hat{A}F^{(l)}W^{(l)}), \quad (5)$$

式中: $F^{(l)}$ 表示输入特征, $F^{(l+1)}$ 表示输出特征, L 表示非线性函数 LeakyReLU, $\hat{A}$ 表示同现关系矩阵 A 的归一化矩阵, $W^{(l)}$ 表示权重矩阵。

为了引导识别器更多地关注同一图像中潜在的同现目标,关系推理的特征结果进一步结合从 C2f 层获得的视觉特征 F_{vision} 。首先,将 F_{vision} 通过最大池化层,然后乘以 $F^{(l+1)}$ 来重新加权。将加权之后的特征先后通过线性变换和 sigmoid 激活函数层之后卷积,最后将卷积后的特征图和视觉特征 F_{vision} 通过 concatenation 操作链接起来输出得到:


$$F_{\text{CAM}} = F_{\text{vision}} \otimes \left(S \left(F_l \left(P \left(f_{\text{vision}} \right) \odot F^{(l+1)} \right) \right) \right) a_2, \quad (6)$$

其中: P 表示最大池化操作, $\odot$ 表示加权相乘, F_l 表示线性变换, S 表示 sigmoid 激活函数, $\otimes$ 表示 concatenation 连接操作, F_{vision} 为 C2f 层的输出特征, $F^{(l+1)}$ 为 GCN 网络的输出特征, F_{CAM} 为 CAM 层的输出特征。总之,CAM 融入同现关系和视觉特征,能够提高视觉特征的注意力,加强识别目标的识别能力。

2.2 面向自遮挡的学习率调整策略

现有深度学习网络模型采用学习率衰减策略来防止训练过程模型损失来回振荡,常见的学习率衰减有余弦学习率调度策略、自适应调度策略等。针对目标自遮挡导致部件特征不准确和学习率振荡问题,本文提出一种面向自遮挡的学习率调整策略(Self-occlusion based Learning Rate Decay,SLD)。在制作数据集时,标签中除了部件类别与真实框坐标之外,还设置了一个 1/0 标签来表示部件是否自遮挡(0 表示未被遮挡),标签格式如图 6 所示。

结合余弦学习率调度策略与自我遮挡标签,生成面向自遮挡的学习率调整策略为:



Class1	Box-x	Box-y	Width	Height	Flag
r-wing	0.086 10	0.898 48	0.145 02	0.131 98	1
head	0.086 10	0.898 48	0.145 02	0.131 98	0
...	...	...	...	...	...

图 6 标签格式

Fig. 6 Label format

$$l_r(b) = \delta_b \left(\min_l_r + \frac{1}{2} \times (\max_l_r - \min_l_r) \times \left(1 + \cos \left(\frac{t}{T} \times \pi \right) \right) \right), \quad (7)$$

$$\delta_b = F_0 / (F_1 + F_0), \quad (8)$$

式中: $l_r(b)$ 为当前 batch 的学习率, $\min_l_r$ 为最小学习率,防止模型停止更新, $\max_l_r$ 为初始学习率; t 和 T 分别表示当前层数与总层数; δ_b 为自遮挡调整参数,在每个 batch 中,统计所有的 0/1 标签个数,来动态调整每个 batch 的学习率参数; F_0 和 F_1 分别表示 Flag 中 0 和 1 的个数。当 F_0 较多时,则表示该 batch 中为被遮挡的部件较多,此时 δ_b 也会增大,增加学习率;反之则表示被遮挡的部件较多, δ_b 则会减小,减小学习率以减少遮挡带来的影响。

3 实验与结果分析

3.1 实验数据集

在室内搭建了目标等效缩比模型验证系统,如图 7 所示。缩比为 1:100 的飞机 F-35 模型固定在转台上,通过转台控制飞机在方位和俯仰上运动;转台在导轨上前后移动,模拟目标远近运动。采样近红外相机 Goldeye CL-030 TEC1 获取分辨率为 640×512 像素的飞机图像,传输到计算机上进行显示和处理。

实验拍摄覆盖多种飞行姿态,标注了飞机头、驾驶舱、左机翼、右机翼、左尾翼、右尾翼、左垂翼、右垂翼和发动机 9 种部件,图 8 是获取的典




图 7 红外目标识别设备与实验环境

Fig. 7 Equipment and experimental environment for infrared target recognition

型目标图像。相对于红外相机,图8(a)是远距离、右偏航情况,飞机左侧自遮挡;图8(b)是远距离、左偏航,右侧自遮挡较少;图8(c)为近距离、正向飞行,未自遮挡;图8(d)是近距离、左偏航,右侧完全自遮挡;图8(e)是近距离、右偏航,左侧自遮挡较少。




图8 目标各姿态与距离样例

Fig. 8 Example of each attitude and distance of target

3.2 评估指标

实验采用精确率(P)与召回率(R)来评价部件识别精度指标。精确率表示预测为正样本中实际正样本所占比例,而召回率表示实际正样本中被预测为正样本的比例:

$$P = \frac{TP}{TP + FP}, \quad (9)$$

$$R = \frac{TP}{TP + FN}, \quad (10)$$

式中: TP 是预测正确的正样本数, FP 是错误预测为正样本数, FN 是错误预测为负样本数。

通过精确率与召回率绘制精度-召回曲线(Average Precision, AP),对所有目标部件计算AP,然后取平均得到mAP来评估部件检测方法对所有部件的识别能力。具体公式如下:

$$AP = \int_0^1 P(R) dR, \quad (11)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i. \quad (12)$$

3.3 消融实验

使用YOLOv8作为基础算法模型进行消融实验,验证所提算法的各个模块对目标自遮挡条件下的部件识别能力,测试结果如表1所示。在加入WCP和CAM模块后,部件识别精确率分别提高了4%和5.7%,召回率提高了6.1%和6.6%,表明融合WCP和CAM模块的方法提升

实验选取4 860张图像,按8:1:1的比例随机划训练集、验证集和测试集。采用PyTorch构建、训练和测试深度学习网络,GPU型号为Titan X;训练方法运用随机梯度下降法(SGD),初始学习率为0.01,批量大小设置为batch_size=4,迭代次数epoch=200。

了不同距离和姿态下目标部件的识别泛化能力。在加入WCP,CAM和SLD等3个模块后,所提方法目标部件识别的精确率和mAP分别达到93.5%和92.2%,而加入CAM模块时的召回率达到94%。

表1 消融实验结果

Tab. 1 Results of ablation experiment (%)						
Base	WCP	CAM	SLD	P	R	mAP
✓				82.4	87.4	87.3
✓	✓			86.4	93.5	91.8
✓		✓		88.1	94.0	91.0
✓			✓	81.8	90.2	87.5
✓	✓	✓	✓	93.5	90.6	92.2

在训练过程中,本方法和YOLOv8模型的边界框损失box_loss与mAP随迭代次数的变化曲线如图9所示。YOLOv8模型的损失值最终稳定在1.51,而本方法的损失值最终稳定在1.09,如图9(a)所示;平均精度曲线最终分别稳定在89.8%和91.1%,如图9(b)所示。SLD模块在训练过程中调整模型的学习率,提升了模型的收敛速度。

图10是所提算法与YOLOv8模型对各部件识别的PR曲线。可以看出,本算法对于各部件的识别准确率AP都达到了90%,平均识别率达




图9 本文算法与原始算法的性能对比
Fig.9 Performance comparison of proposed algorithm with original algorithm

到 92.2%，识别概率更高，更稳定。值得注意的是，YOLOv8 模型对各部件识别准确率差别较大，飞机头识别率为 0.944，而对发动机的识别率却仅有 59.8%，平均识别率为 87.3%

3.4 对比实验

为验证本算法对具有红外目标自遮挡部件的识别性能，选取 YOLOv8 模型、WCL-YOLOv4-tiny 算法^[20]和混合任务级联(Hybrid Task Cascade, HTC)算法^[21]进行对比测试，测试结果如表 2 所示。使用各部件的 AP 值和 mAP@0.5 作为性能指标。由表 2 可知，本算法对具有目标自遮挡的部件识别平均精度达到 92.2%，相较于 YOLOv8，WCL-YOLOv4-tiny(表中简称 tiny)与 HTC 方法分别提高了 4.9%，2.6% 和 3.2%。从各个部件的 AP 值关系可以看出，尽管 YOLOv8

和 WCL-YOLOv4-tiny 算法在某些特定部件，如左垂翼上的表现优秀，但对发动机等部件识别差异大，这是仅凭视觉特征所带来的问题。本算法对每个部件的识别精确率都达到了 90% 以上，mAP 值也是最佳的。

表 2 不同算法的对比结果

Tab. 2 Comparison results of different algorithms

类别	YOLOv8	tiny	HTC	Proposed
飞机头	0.944	0.945	0.952	0.907
驾驶舱	0.886	0.869	0.887	0.919
左机翼	0.933	0.953	0.946	0.955
右机翼	0.884	0.907	0.900	0.969
左尾翼	0.892	0.891	0.932	0.896
右尾翼	0.795	0.824	0.786	0.905
左垂翼	0.982	0.965	0.980	0.927
右垂翼	0.948	0.955	0.933	0.904
发动机	0.598	0.682	0.694	0.917
mAP	0.873	0.896	0.890	0.922

图 11 是不同姿态与距离下飞机目标部件的识别结果(彩图见期刊电子版)。为便于观察，按照暗红、绿、黄、蓝、紫、青、灰、棕、红色等颜色对目标部件进行可视化标注，将 3 种对比算法的识别区域等比例放大。

对于遮挡较少且距离较近的姿态，如第一行与第二行，4 种算法均表现出较好的识别性能，但 YOLOv8 与 HTC 出现少量重复检测飞机头与驾




图 10 各部件的 mAP 曲线
Fig. 10 mAP curves for each component

驶舱的情况。

在第三行中,目标距离相对较远,部件自遮挡程度较小,3种对比算法对飞机尾部的识别精度明显下降,尾翼漏检的情况较多。YOLOv8与WCL-YOLOv4-tiny漏检右尾翼,HTC算法则漏检两侧尾翼。相比而言,本文算法没有发生漏检现象,受距离影响较小。

在第四行和第五行中,目标距离较近,但是自遮挡程度较高。对于没有遮挡的飞机头和驾驶舱,4种算法均表现出较好的性能。对于第四

行中飞机左侧遮挡情况,3种对比算法没有识别出飞机左侧的部件,如左机翼和左尾翼。对于第五行中飞机右侧遮挡情况,YOLOv8仅识别出左侧机翼和垂翼,WCL-YOLOv4-tiny与HTC错误地识别了左侧机翼与垂翼,而本算法均能较好地识别出左右两侧部件。

综上可知,本算法对自遮挡较多的部件,如发动机、左右侧机翼等有着更佳的识别性能,对不同的姿态和距离下的各部件识别能力最高,误检率较低,适合识别具有自遮挡的目标部件。




图11 各姿态距离下飞机部件识别结果对比

Fig. 11 Comparison of aircraft component recognition results at various attitudes and distances

4 结 论

针对部件识别中目标具有自遮挡、视觉特征

不明显、特征随距离变化较大等问题,本文提出一种基于知识图谱的红外目标部件识别方法。该算法使用整体局部识别方法,关联和融入与目

标相对应的知识图谱,融合了部件关联性注意力模块与面向自遮挡的学习率调整策略。通过室内目标等效缩比模型系统测试验证,本方法显著提升了目标部件识别的精度和召回率,精度达到92.2%,解决自遮挡等情况下视觉特征不足带来的部件识别难题。

参考文献:


- [1] KONG T, YAO A B, CHEN Y R, *et al.* HyperNet: towards accurate region proposal generation and joint object detection[C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016. VegasLas, NV, USA. IEEE, 2016: 845-853.
- [2] CHEN T, SAXENA S, LI L L, *et al.* Pix2seq: a language modeling framework for object detection [EB/OL]. 2021: 2109.10852. <https://arxiv.org/abs/2109.10852v2>.
- [3] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements [EB/OL]. 2024: 2410.17725. <https://arxiv.org/abs/2410.17725v1>.
- [4] OU J P, ZHANG J. Investigation on recognition performance of harvesting robot using regions of interest histogram of oriented gradients feature based on improved fuzzy least square support vector machine[J]. *Mathematical Problems in Engineering*, 2021, 2021(1): 6650367.
- [5] 蔡引娣, 张殿鹏, 孙梓盟, 等. 基于改进YOLOv8模型的增材制造微小气孔缺陷检测及其尺寸测量[J]. *光学精密工程*, 2024, 32(21): 3222-3230.
CAI Y D, ZHANG D P, SUN Z M, *et al.* YOLOv8 model-based additive manufacturing micro porosity defect detection and its dimension measurement[J]. *Opt. Precision Eng.*, 2024, 32(21): 3222-3230. (in Chinese)
- [6] 蒋占军, 吴佰靖, 马龙, 等. 基于金字塔边缘增强的自矫正低光照目标检测[J]. *光学精密工程*, 2024, 32(20): 3099-3111.
JIANG ZH J, WU B J, MA L, *et al.* A self correcting low-light object detection method based on pyramid edge enhancement [J]. *Opt. Precision Eng.*, 2024, 32(20): 3099-3111. (in Chinese)
- [7] 宋宗莹, 王兴中, 曾杉, 等. 基于改进YOLOv7的无人机图像铁路接触网部件目标检测方法[J]. *测绘通报*, 2024(11): 108-114.
- [8] 蓝贵文, 徐梓睿, 任新月, 等. 基于YOLOv8n改进的航拍输电线路图像多类电力部件检测算法[J]. *测绘通报*, 2024(9): 38-43, 49.
LAN G W, XU Z R, REN X Y, *et al.* An improved algorithm for detecting components of power transmission lines from aerial inspection images[J]. *Bulletin of Surveying and Mapping*, 2024(9): 38-43, 49. (in Chinese)
- [9] ALQAHTANI H, KUMAR G. Deep learning-based intrusion detection system for in-vehicle networks with knowledge graph and statistical methods [J]. *International Journal of Machine Learning and Cybernetics*, 2025, 16(5): 3539-3555.
- [10] CHEN X L, LI L-J, LI F-F, *et al.* Iterative visual reasoning beyond convolutions[C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018. Salt Lake City, UT, USA. IEEE, 2018: 7239-7248.
- [11] CHEN Z M, WEI X S, WANG P, *et al.* Multi-label image recognition with graph convolutional networks[C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019. LongBeach, CA, USA. IEEE, 2019: 5172-5181.
- [12] HU H, GU J Y, ZHANG Z, *et al.* Relation networks for object detection[C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018. Salt Lake City, UT, USA. IEEE, 2018: 3588-3597.
- [13] FANG Y, KUANG K, LIN J, *et al.* Object detection meets knowledge graphs[C]. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*. August 19-26, 2017. Mel-

作者贡献声明:

刘海毅:检测方法的提出,数据管理与处理,可视化呈现,以及论文构思和撰写;
李正周:项目管理,实验的设计与指导;
李傲燃:数据集制作;
刘海涛:实验平台搭建。

- bourne, Australia. *International Joint Conferences on Artificial Intelligence Organization*, 2017: 1661-1667.
- [14] JIANG C, XU H, LIANG X, *et al.* Hybrid knowledge routed modules for large-scale object detection[J]. *Advances in Neural Information Processing Systems*, 2018, 31.
- [15] XU H, JIANG C H, LIANG X D, *et al.* Reasoning-RCNN: unifying adaptive global reasoning into large-scale object detection[C]. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019. LongBeach, CA, USA. IEEE, 2019: 6412-6421.
- [16] XU H, JIANG C H, LIANG X D, *et al.* Spatial-aware graph relation network for large-scale object detection [C]. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019. LongBeach, CA, USA. IEEE, 2019: 9290-9299.
- [17] RIDNIK T, BEN-BARUCH E, NOY A, *et al.* ImageNet-21K pretraining for the masses [EB/OL]. 2021: 2104.10972. <https://arxiv.org/abs/2104.10972v4>.
- [18] PENNINGTON J, SOCHER R, MANNING C. Glove: global vectors for word representation[C]. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha, Qatar. Stroudsburg, PA, USA: ACL, 2014: 1532-1543.
- [19] NAYEF B H, ABDULLAH S, Siti Norul Huda Sheikh, SULAIMAN R, *et al.* Optimized leaky ReLU for handwritten Arabic character recognition using convolution neural networks[J]. *Multimedia Tools and Applications*, 2022, 81(2): 2065-2094.
- [20] PRASETYO E, SUCIATI N, FATICHAH C. Yolov4-tiny with wing convolution layer for detecting fish body part [J]. *Computers and Electronics in Agriculture*, 2022, 198: 107023.
- [21] CHEN K, OUYANG W, LOY C C, *et al.* Hybrid task cascade for instance segmentation [C]. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019. LongBeach, CA, USA. IEEE, 2019: 4969-4978.

作者简介:



刘海毅(2000—),男,重庆梁平人,硕士研究生,主要研究方向为红外目标的智能识别。E-mail: 17723808772@163.com

通讯作者:



李正周(1974—),男,重庆人,博士,教授,博士生导师,主要研究方向为微弱目标识别、雷达信号识别与跟踪。E-mail: lizhengzhou@cqu.edu.cn