

# 白蚁分区式微方向感知的精确形态识别

邹峥<sup>1</sup>,雷雨晟<sup>1</sup>,刘石坚<sup>2</sup>,王定一<sup>3</sup>,邱学炜<sup>1</sup>,史雯雯<sup>2</sup>,周校通<sup>2</sup>

(1.福建师范大学计算机与网络空间安全学院,福建福州350117;2.福建省大数据挖掘与应用技术重点实验室(福建理工大学),福建福州350118;3.福建师范大学地理科学学院,福建福州350117)

**摘要:**提出分区式微方向感知的自动形态分析方法,采用分区式思想细化目标,间接增加形态差异的显著性。选择旋转矩形表征目标和更多方向信息,在识别时引入多层局部空间感知模块,将方向与特征直接关联,同时融合双支空间金字塔模块,强化浅层特征复用,提高了计算效率。将主流旋转目标检测方法、关键点检测方法与本文方法对比,结果证明在提取高干扰的小目标的方向和位置方面,本文方法具有更好的精确度和鲁棒性。

**关键词:**白蚁形态测量;旋转目标检测;关键点检测;物种鉴定;自动形态识别

**中图分类号:**TP391 **文献标志码:**A

**引用格式:**邹峥,雷雨晟,刘石坚,等.白蚁分区式微方向感知的精确形态识别[J].山东大学学报(理学版),2026,61(1):76-84,93.

## Precise morphological recognition with zonal micro-direction for termites

ZOU Zheng<sup>1</sup>, LEI Yusheng<sup>1</sup>, LIU Shijian<sup>2</sup>, WANG Dingyi<sup>3</sup>, QIU Xuwei<sup>1</sup>, SHI Wenwen<sup>2</sup>, ZHOU Xiaotong<sup>2</sup>

(1. College of Computer and Cyber Security, Fujian Normal University, Fuzhou 350117, Fujian, China; 2. Fujian Provincial Key Laboratory of Big Data Mining and Applications (Fujian University of Technology), Fuzhou 350118, Fujian, China; 3. School of Geographical Sciences, Fujian Normal University, Fuzhou 350117, Fujian, China)

**Abstract:** The partition-based approach is used in the paper to refine the target by indirectly enhancing the saliency of morphological differences. Rotational moment-based representation is provided more directional information, and a multi-layer local spatial perception module is incorporated to directly associate direction with features. Furthermore, a dual-branch spatial pyramid module is introduced to enhance the reuse of shallow features and improve computational efficiency. In our experiments, the rotational object detection method, the key point detection method, and the proposed method are compared, and it is demonstrated that our method achieves better accuracy and robustness in extracting the direction and position of small targets under higher interference.

**Key words:** measurement of termite morphology; oriented object detection; key point detection; species identification; automatic morphology recognition

## 0 引言

白蚁深居潮湿地下,以木质纤维为食,主要分布在亚热带地区,我国白蚁共有4科44属473种<sup>[1]</sup>。现有研究发现白蚁具有分解植物残体,改善土壤结构的生态特点<sup>[2]</sup>。分析形态差异性认知白蚁生态地位、理解白蚁多样性的重要前提,同时形态分析是物种鉴定的直接量化依据<sup>[1-2]</sup>,随着生态环境变化,现有白蚁分类体系有待修正和扩展,而基于形态学分析的物种鉴定,是目前最广泛和快捷的鉴定方法。本文以白蚁电子显微图像为对象,提取白蚁体躯中物种相关的差异化形态为研究对象,实现细微特征的精准识别。

形态学分析是昆虫研究的常规工具。传统形态分析依赖人工定位和测量,操作繁琐且效率低下,无法满

足实际需求。现有自动形态分析,以解剖学位置点作为输出,即关键点识别,通过关键点位置提取最终数值指标。如 Hoang 等<sup>[3]</sup>提出昆虫翼静脉与翼缘交叉处选取关键点,结合高斯采样定位关键点。João 等<sup>[4]</sup>用 U-Net 定位蜜蜂翅膀的 19 个关键点。

白蚁作为地下穴居昆虫,相对经济作物类昆虫如蝴蝶,蜜蜂等捕获难度较大,针对白蚁的自动形态识别<sup>[5-10]</sup>研究较少,且现有昆虫使用的关键点检测策略并不适用于本任务。

首先,昆虫类型不同,点位置选择难度不同。本文以无翅白蚁中工蚁和兵蚁为研究对象,研究对象体表缺乏翅膀上的明显交叉点,白蚁头部和前胸盖板连接区域,纹理相似,即便是专业人士也很难确定,而且点标效率较低,单个白蚁的形态点可能多达十几个。其次,白蚁形态学指标更关注线段代表的矢量距离,如头最宽距离,从点标注还原具有更丰富信息的矢量特征,由于点表达能力有限,造成最终形态分析偏差较大,因此应提取更丰富和高级空间信息才能保证后续形态计算的精确。最后,白蚁图像成像时的不确定性。拍摄时因白蚁姿态不一,当姿态扭曲程度严重时,身体各部位和拍摄点距离差异较大,导致身体轮廓和形态呈现不同程度的模糊,加上白蚁浸泡液的反光,使白蚁形态部分缺失甚至完全缺失,增加了识别难度。

针对传统关键点识别局限,更精确识别扭曲白蚁,本文提出分区式的旋转矩形表征白蚁体躯,这类表征直接关联方向,比点包含更好空间信息,且标注简单。为提升检测对方向的感知能力,在特征提取阶段引入局部空间感知模块,增强精确位置和方向信息,保证局部微小特征的准确性。在特征融合阶段,设计双支空间金字塔模块,提升局部和全局特征的有效融合,防止因部分信息缺失导致的特征失效。

## 1 相关工作

### 1.1 传统形态分析

传统人工形态分析常用双目显微镜观察形态,在可视化图像上利用线段测量工具定位起点和终点,绘制距离线段,计算线段并显示测量结果。人工测量可视化结果如图 1 所示。

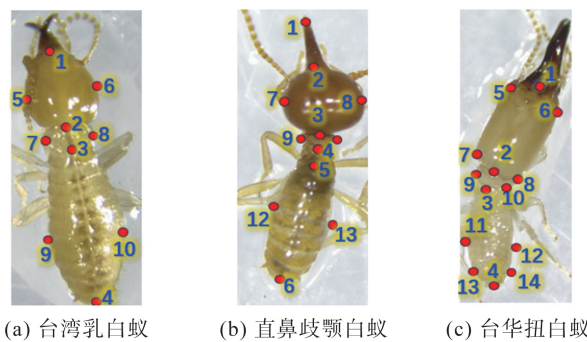


图 1 三类白蚁手工标注点区别  
Fig.1 Various types of termites are manually labeled differently

传统分析方法依赖人工标记,不同类型白蚁,其形态特征点数量也不同,某些类型白蚁的特征点有时多达几十个,逐一标注效率低下,且因标记位置主要为点,其尺寸细小且并不唯一,常容易因个体主观经验差异而产生偏差,因此,结合深度学习实现自动化形态分析,是昆虫形态学的发展趋势。

### 1.2 基于昆虫关键点的形态自动分析

现有昆虫自动形态分析,仍以点目标为重点,结合关键点检测和计量方法分析。关键点检测方法分为传统方法与深度学习<sup>[11]</sup>。传统检测基于图像梯度、纹理、角点等手工特征检测<sup>[12]</sup>,而深度学习方法主要以卷积神经网络学习特征表达<sup>[13]</sup>。由于深度学习模型在复杂场景下具有更强泛化能力,逐渐成为主流<sup>[11]</sup>。例如 Le 等<sup>[14]</sup>提出关键点检测网络(elementary block network, EB-Net),迁移学习人脸关键点先验提高检测准确性。Geldenhuys 等<sup>[15]</sup>利用 16 层视觉卷积分类(visual geometry group 16-layer convolutional network, VGG16)过滤不完整翅膀的舌蝇图像,以指定的 11 个解剖关键点为目标,采用 50 层的残差网络(residual network with 50 layers, ResNet50)回归和 UNet++分割模型结合预测关键点,回归模型在计算效率上具有优势,而分割模型则精度更高。

现有昆虫关键点检测虽取得一定成果,但直接应用白蚁图像,仍存在以下局限。首先,关键点检测模型

依赖手工标注点,标注偏差会因标注规模累积成更大误差;其次,白蚁形态学指标更关注线段代表的矢量距离,从点结果还原矢量特征,会因点表达能力有限,造成白蚁实际形态不精确;最后,现有方法识别精确度对关键点选择敏感,但关键点选择却依赖经验且具有主观性。

### 1.3 旋转目标检测

通用目标检测方法,用单一方向的水平矩形表示目标<sup>[16-17]</sup>难以反映白蚁姿态实际方向<sup>[18-19]</sup>,容易识别出大量无关信息<sup>[20]</sup>,造成较大误差。因此本文主要关注旋转目标检测方法。

目前旋转目标检测实现分为3类。第1类基于旋转不变形,提取目标旋转不变特征后,使目标还原成水平方向再检测<sup>[21]</sup>,如空间变换网络(spatial transformer network, STN),但当目标倾斜严重时,可能包含更多背景,严重影响检测效率;第2类是基于无锚点机制,与带旋转框单阶段检测网络(refined single-stage detector with rotatable boxes, R3Det)与基于锚点的方法<sup>[22]</sup>不同,无锚点机制直接以目标方向,宽度,高度为预测结果<sup>[23]</sup>;第3类是基于损失函数角度化,即在目标函数中设计角度参数,但由于角度固定周期容易造成回归的不连续性,Qian等<sup>[24]</sup>提出一种调制旋转损失消除突增的边界损失。单发对齐网络(single-shot alignment network, S2Anet)结合无锚点检测和角度回归的损失函数优点<sup>[25]</sup>,引入特征对齐模块和对齐卷积层对齐特征,提高检测精度,但对齐模块增加了计算复杂度。单次检测网络YOLOv8直接预测目标角度<sup>[5]</sup>,无需额外对齐,同时采用跨阶段局部网络(cross stage partial darknet, CSPDarkNet)提取网络特征,识别效率较高,因此本文采用YOLOv8作为识别核心模型结构,其主干网因采用了多层卷积结构,能够从图像中捕捉边缘、角点、纹理等局部特征,为后续形态分析提供丰富的信息,但在识别白蚁各微小部位时,缺乏专门的对齐机制会造成一定的精度下降。

综上所述研究现状和局限性,本文提出基于白蚁分块的微方向感知的精确识别方法。通过缩小范围,分区识别增加微小特征显著性,通过提高旋转目标检测的局部感知能力,完善上下文空间关联增加识别精确性。

## 2 基于分区和微方向感知的形态分析

本文提出两阶段的分析方法,由分块式目标构建,微方向感知的目标识别,以及旋转矩形的测量组成,如图2所示。第1阶段目标是表征和识别白蚁形态,由分块式构建和微方向识别组成,其中微方向感知关联局部和全局空间,是形态分析的核心;第2阶段是识别结果的量化。(1)分块式目标构建。通过白蚁解剖学特点,细化白蚁成3个主要特征密集单元,即头,胸和腹。细化缩小范围,间接增加单元内特征差异的显著性。(2)微方向的目标识别,用矩形替代传统点表征识别单元,考虑到白蚁姿态扭曲,采用基于微方向感知增强的旋转目标检测识别,获取精确的矩形结果。(3)旋转矩形指标计算。根据矩形的图形结果,提取和计算形态相关的主要指标。

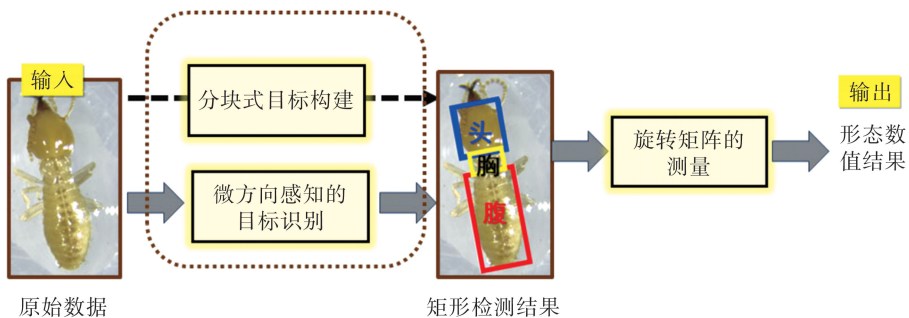


图2 两阶段形态自动分析总流程

Fig.2 The overall process of two-stage automatic morphological analysis in this article

### 2.1 分块式目标构建

分块策略既能划分白蚁形态粗语义,也能保证后续识别精确。通过观察大量样本,结合现有形态学文献<sup>[1]</sup>,筛选高显著形态学指标,本文发现白蚁头、胸、腹等关键部位为差异性形态密集分布区,如头宽、头长、前胸背板长等<sup>[26]</sup>,如表1所示。

表 1 白蚁类型相关的量度特征  
Table 1 Measurement characteristics related to termite types

特征变量	定义	分布区域	特征变量	定义	分布区域
头长	上颚基至头后缘最大长度	头	前胸背板宽	前胸背板的最大宽度	胸
头宽	头部最宽处的宽度	头	腹部长	腹部的最大长度	腹
头长宽比	头形状	头	腹部宽	腹部的最大宽度	腹
前胸背板长	前胸背板中线的最大长度	胸	体长	从头顶到腹尾最长度	头,胸,腹

根据白蚁差异化形态分布的 3 个主要区域,本文将白蚁体躯划分为 3 部分:头、胸和腹部,如图 3 所示。分段感知白蚁微小形态,采用角度感知的矩形框表征白蚁体躯。相比点表征,矩形框表征能更准确表达各分区方向,具有相对空间信息特点,同时矩形长、宽是产生形态学指标的基础和关键,与矩形框直接相关。

### 2.2 基于微方向感知的目标识别

受无锚框旋转检测高效率启发,本文采用经典的 YOLOv8 模型。由于 YOLOv8 对小目标提取精度有限,白蚁识别单元中,特别前胸尺寸尤其微小,为增强角度和位置的精确识别,本文提出基于微方向感知的目标识别方法,从特征提取和特征融合 2 个层面,引入 2 个模块,如图 4 所示。在特征提取层引入多层局部空间感知模块,提高各层特征提取的精确度,即在包含卷积批归一化(convolution and batch normalization and sigmoid linear unit, CBS)、快速跨阶段局部特征融合(cross stage partial feature fusion, C2f)等基础特征提取后,分 3 阶段分别引入位置注意力(coordinate attention, CA)模块,显式性采用局部坐标位置与特征直接关联,增加方法对位置和方向的感知能力。在特征融合层引入双支金字塔(dual-branch spatial pyramid pooling fast, DSPPF)模块,增加长跨层连接,强化浅层特征复用,提高计算效率,丰富特征图融合的尺度信息,能更好地提取白蚁这类尺度差异较大对象的语义信息。




图 3 三分块矩形表征目标  
Fig.3 Three block rectangles representing three targets

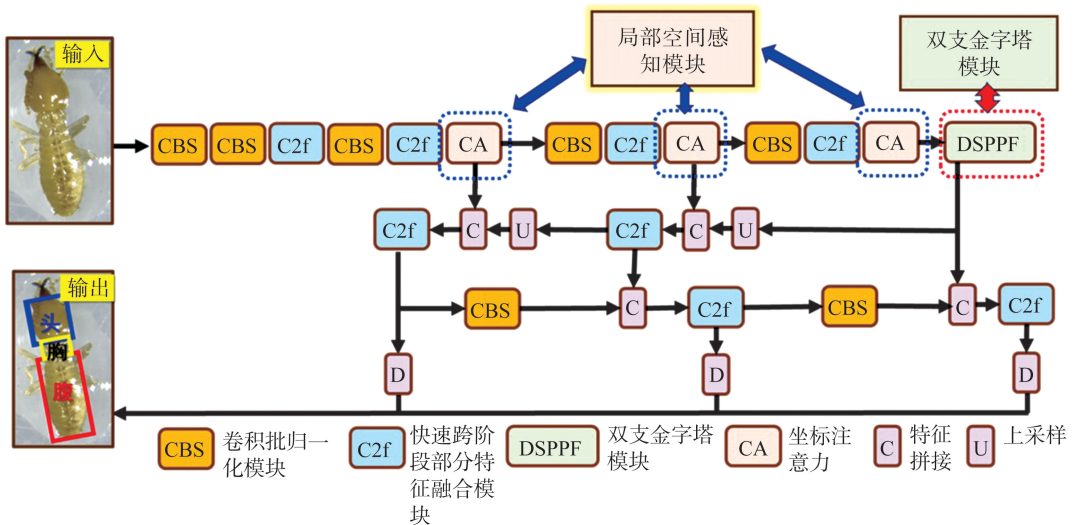


图 4 基于微方向感知的目标识别方法的结构示意图  
Fig.4 Structural diagram of target recognition method based on micro directional perception

### 2.3 多层局部空间感知模块

由于白蚁的头部、胸部、腹部占体表面积 90% 以上,仅依靠卷积网络,无法为相距较远的局部特征建立关联,白蚁各部分单元尺寸微小,这些小而相连的目标特征通常比较稀疏,白蚁各组成单元常因姿态随机,呈现方向偏差,因此位置和方向的准确性是本文精确识别的关键。

受到文献[27]的坐标注意力模块 CA 启发,该模块具有水平和垂直 2 个基本方向聚合特征,使其能关注多方向特征。本文在 YOLOv8 的 3 个特征提取单元中,分别引入 3 个坐标注意力模块,保证方法在不同尺度特征中,都能保持对目标方形和位置的敏感性,提高对小尺寸目标的识别精度,同时,坐标注意力保留精确

的位置信息,提高原有方法的目标定位能力,此外,由于坐标注意力本身轻量化的结构,无需增加额外开销,可独立地嵌入基本网络中,保证提高特征提取能力同时不会降低识别效率。本文提出的多层局部空间感知模块,通过强化空间位置和方向信息,为后续还原信息以及特征融合提供了更完整的细节。

## 2.4 双支金字塔模块

YOLOv5s 使用快速空间金字塔池化模块(spatial pyramid pooling fast, SPPF),该模块通过拼接多个串行的同大小的最大池化层,实现不同大小的感受野特征的融合,池化层结合串行结构,降低参数规模,具有较高的效率,但也因使用池化层造成一定程度信息损失,导致目标不确定。白蚁图像在拍摄过程中常受光源不均匀、高光等因素干扰,造成图像背景复杂,增加目标检测的难度。而快速空间金字塔模块因信息缺失,难以处理背景干扰问题,导致模型对白蚁边缘和细节,识别能力下降。

受到跨阶段局部网络(cross stage partial networks, CSPNet)结构中跨阶段连接策略<sup>[28]</sup>的启发,本文提出双支金字塔模块,即 DSPPF 模块,具体结构如图 5 所示。该模块将金字塔池化和跨阶段连接策略相结合,在增强模型的学习能力的同时,兼顾轻量化设计,提高推理速度。改进的金字塔模块将输入特征划分成 2 支。一支串联 3 个池化窗口为  $5 \times 5$  最大池化层,实现特征下采样,得到 3 个不同尺度的感受野特征;另一支对原始特征进行卷积操作,最后,融合两支特征,生成最终特征图。通过这样方式,池化提取多尺度特征,通过重用原特征实现跨阶段连接,预防信息丢失,更好地捕捉复杂背景区域中白蚁的语义信息,从而提升白蚁检测的平均精度。

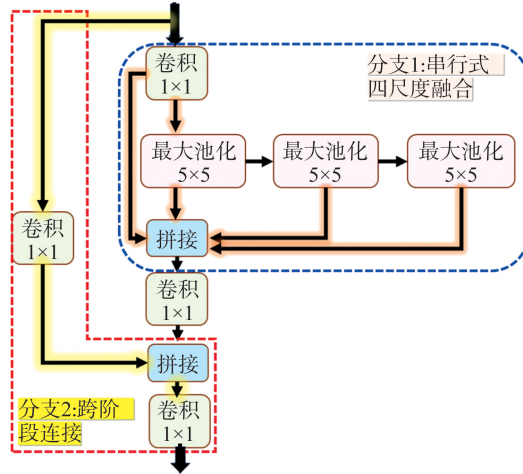


图 5 双支金字塔模块

Fig.5 The dual-branch spatial pyramid pooling fast module

## 2.5 基于旋转矩形的测量分析

本文形态分析以旋转矩形表征形态,取代传统的点表征。将白蚁整体分离成 3 个包含头、胸和腹类型标识的矩形结果。点是标量,仅能表示位置信息,而矩形是矢量,空间信息更多,不仅能表示位置,还能提供大小和方向信息,如中心坐标、矩形目标的宽度和高度、旋转角度等。旋转矩形提取表 1 所有指标,具体可分为两类:一类是直接指标,如头长、头宽、头角度等可直接从矩形结果如矩形长宽得到;另一类为间接指标,如体长等,在矩形基础数值进行简单计算即可。此外矩形结果包含区域统计的完整信息,不仅可以计算已定义的指标,还可以探索扩展指标如身体弯曲度等,使形态分析更灵活和多样化,为后续形态指标探索的提供更多可能性。

形态指标量化的高效率在很大程度上是旋转矩形的策略的贡献。这类矩形目标提供了远超过点表达的空间信息,同时又大大简化了标注难度,提高了标记效率,提供更完备的空间信息,这些信息是保证精确形态认识的重要前提。

## 3 实验及结果分析

### 3.1 数据集构建与实验配置

本数据集共包含 420 张台湾乳白蚁图像,该图像使用双目显微镜拍摄,矩形框使用 X-AnyLabeling 软件标注。为提高方法对角度感知能力,对原始数据采用旋转策略扩充。首先将原始数据按照 9:1 划分训练集和验证集,然后对训练集和验证集采用 11 种不同旋转角度:  $30^\circ$ 、 $60^\circ$ 、 $90^\circ$ 、 $120^\circ$ 、 $150^\circ$ 、 $180^\circ$ 、 $210^\circ$ 、 $240^\circ$ 、 $270^\circ$ 、

300°和 330°进行数据增强,最终得到 5 040 张图像。

本文实验运行在 Nvidia V100 8GB 显卡机器上。训练超参数设置为:总训练轮次为 500, batchsize 为 8、输入图像尺寸为 640×384、学习率为 0.01、开启马赛克增强、±10°范围内随机旋转图像,采用渐进式交并比计算方法作为本方法的损失函数。

### 3.2 旋转目标检测方法的性能评估

本实验从以下几个方面评估。

(1) 目标识别的指标评估。本文采用 3 种指标量化评估,包括精确率、召回率,交并比阈值 0.5 下的平均精度(记为平均精度@ 50),以及交并比阈值从 0.5~0.95 的平均精度(记为平均精度@ 50-95)。结果如表 2 所示,各行自上而下依次表示检测方法在完整躯躯、头部、胸部、腹部上的识别性能。模型整体召回率高达 97.2%,整体平均精度在阈值为 0.5 时达到 97.5%,证明本文目标检测方法对完整躯躯识别精度达到较高水平;同时本文分别统计头部、胸部以及腹部 3 个分区单元的结果,发现即便对于前胸背板这类只占躯干 1/10 的小目标,其精确度为 84.9%,与精确最高的头部只差 1%,这证明了本文方法对小目标具有较好的鲁棒性。

表 2 本文目标识别方法的性能量化评估

Table 2 Quantitative evaluation of performance of target recognition method in this article

分区	精确率	召回率	平均精度@ 50	平均精度@ 50-95
完整躯躯	0.852	0.972	0.975	0.874
头部	<b>0.857</b>	0.965	0.977	<b>0.916</b>
胸部	0.849	0.958	0.967	0.818
腹部	0.851	<b>0.994</b>	<b>0.981</b>	0.888

注:加粗数据为最优值。

(2) 对比经典旋转目标检测,验证本文目标识别方法对角度感知能力。本实验设计 4 类结果可视化对比:基于锚点的 R3Det<sup>[22]</sup>、基于无锚点的 S2ANet<sup>[25]</sup>、YOLOv8 以及本文方法。选取 3 类图片如图 6 所示,从上向下,第 1 行代表扭曲较严重,高光面积较多,干扰较强的情况;第 2 行代表轻微扭曲,且存在中等高光的情况;第 3 行代表无扭曲,光照均匀的情况。观察矩形检测结果,可发现 YOLOv8 方向感知能力有限,对局部高光增多,全局姿态偏差较大时,方向感知能力快速下降。本文方法因强化了方向特征和改善了多尺度融合,因此对形态缺乏最严重的图像,依然保持精确的方向和位置感知能力。R3Det 因缺乏特征对齐模块,在 4 种方法中方向感知能力最差,而 S2ANet 更关注锚点位置,因此矩形范围比 R3Det 准确,但遇到低对比度的前胸背板时,旋转锚点的方向性敏感度不高,出现了漏检的情况。

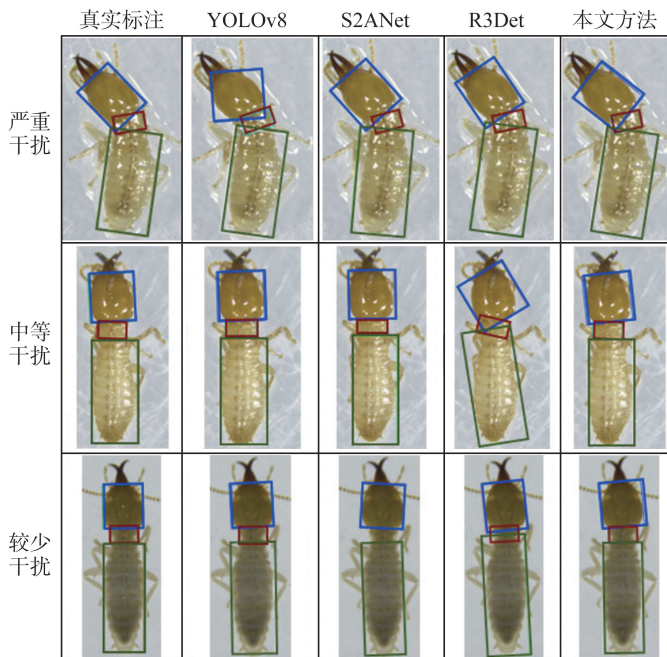


图 6 3 种主流旋转目标检测与本方法对比

Fig.6 Comparison of three mainstream rotating object detection methods with this method

(3) 对比矩形与 keypoints 的方向感知能力。关键点检测方法选择高分辨检测模型 (high resolution network, HRNet), 用 Labelme 标注软件, 手工标注 10 个关键点作为 HRNet 的真实值。对比结果按头、胸、腹分别展示如图 7 所示, 各分区显示了 3 根线段: 黄实线, 红实线, 以及黑线。黄线和红线代表关键点表达, 黄线是 HRNet 预测的关键点的连线, 而红线是手工标注点连线, 黑线代表方框表达, 由本方法预测的矩形生成的连线。3 个分区中, 黑虚线都比黄线方向更接近手工标记红线, 相比其他分区, 前胸盖板由于其面积较小, 关键点识别误差变大, 黄色连线偏差最大。证明了本文使用矩形表征比传统关键点表达, 更适合感知微小方向差异, 具有更精确感知的能力。




图 7 关键点检测和旋转矩形检测对比

Fig.7 Comparison of the keypoint detection and rotated rectangular box detection

(4) 对比矩形与 keypoints 的形态指标结果。本实验选择涵盖头、胸以及腹的 6 个主要指标, 统计两类识别结果与真实值的平均误差。本文白蚁整个体躯长度范围为 5~6 mm, 从表 3 可以看出, 旋转框产生的 6 个指标, 平均误差都在 0.08 mm 内, 且都比关键点指标更接近真实值。头部作为扭曲最小单元, 关键点结果和矩形结果比较接近, 而前胸盖板这类占比最小单元, 关键点结果误差高达 0.05 mm, 而矩形误差仅约 0.03 mm, 这证明了本文矩形检测对小目标更精准。以上结果证明了旋转目标测量在大多数情况下优于关键点测量, 能够提供更精确的测量结果。

表 3 关键点和旋转矩形的形态指标误差对比

Table 3 Comparisons of shape index errors between key points and rotating rectangle

形态指标	关键点平均误差/mm	旋转方框平均误差/mm
头长	0.059 610±0.003 252	0.055 775±0.002 048
头宽	0.062 902±0.004 337	0.032 508±0.00 1379
胸长	<b>0.053 349±0.001 412</b>	<b>0.024 218±0.000 656</b>
胸宽	0.055 775±0.002 048	0.032 508±0.001 379
腹长	0.061 898±0.005 285	0.041 293±0.090 437
腹宽	0.089 777±0.004 079	0.085 600±0.005 214

注: 粗体表示最优值。

### 3.3 消融实验

用于多层局部空间感知的 CA 方法模块和用于有效特征融合的 DSPPF 方法模块, 为验证本文方法对这 2 个核心模块精确识别的效果, 本实验设计了 4 类模型对比: 原始 YOLOv8 模、仅添加多层局部空间感知模块的 YOLOv8+CA 模型、仅添加双支空间金字塔模块的 YOLOv8+DSPPF 模型、以及本方法使用的 YOLOv8+CA+DSPPF 模型。

4 类模型检测结果的指标对比如表 4 所示, 由于 YOLOv8 对位置和方向特征增强, 精确率是 4 类模型中最低仅 76.5%; 添加 CA 时, 4 个指标有 2%~5% 的提升; 仅添加 DSPPF 时, 相比单加 CA, 4 个指标提高幅度更大, 特别是召回率增加 7%, 验证了双支的跨层连接是保证特征有效提取的关键。当添加 2 个模块后, 结果精确率达到最高 85.2%, 证明了对特征提取和特征融合改进后, 对精确识别目标是可行而有效的。

表 4 本文目标识别方法的消融实验

Table 4 The ablation experiment of our method

方法类型	精确率	召回率	平均精度@ 50	平均精度@ 50-95
YOLOv8	0.765	0.856	0.881	0.848
YOLOv8+CA	0.791	0.881	0.902	<b>0.911</b>
YOLOv8+DSPPF	0.835	0.962	0.963	0.909
本文方法	<b>0.852</b>	<b>0.972</b>	<b>0.975</b>	0.874

注: 粗体表示最优值。

### 3.4 本方法泛化性评估

为更好评估本方法泛化性能,针对2类其他类型图像进行验证:其他类型白蚁和其他昆虫。

(1) 本方法对其他类型白蚁的泛化能力。引入5类白蚁:海南土白蚁、黄翅大白蚁、黄胸散白蚁、台华扭白蚁和直鼻歧颚白蚁。每类选取20张,采用迁移学习策略训练模型,冻结主干网络参数,设置模型训练轮次为300,训练批量 *batchsize* 为8,学习率为0.001,采用早停策略, *patience* 为100,即连续100轮内未提升时自动终止训练。识别结果如图8(a)~(e)所示,尽管5类类型、尺度和形态存在显著差异,如头近似锥形的直鼻歧颚白蚁、以及头腹尺寸比与台湾乳白蚁差异最大的台华扭白蚁,本方法依然可以准确定位区块。

(2) 本方法识别其他昆虫的泛化能力。引入4类和白蚁种属较远的昆虫:属于弹跳目的爪跳虫、属于鞘翅目的卡洛虎甲虫,潜虎甲虫和巨颚虎甲虫如图8(f)~(i)所示,每类采用16张图片训练,亦采用相似的迁移策略训练。由于物种存在较大差异,未冻结网络参数,模型全量微调。模型训练轮次为500,训练批量 *batchsize* 为8,学习率为0.01,采用早停策略,设置 *patience* 为100。结果表明,即使背景更复杂、头胸尺度更接近、背部纹理差异较大的虎甲虫,本方法依然可以准确识别3区块,验证了本文方法具有较强的通用性与适应性,具备应用于其他昆虫形态学分析任务的潜力。

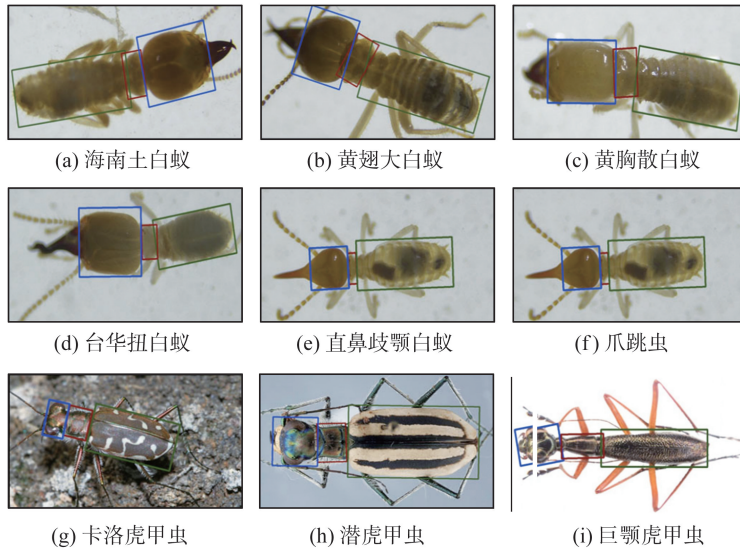


图8 本文目标识别方法在其他物种上的实验结果  
Fig.8 The experimental results of the model on other species

## 4 结语

本文以白蚁显微图像为研究对象,以精确识别光照不均、姿态扭曲的目标形态为目标。针对目前主流昆虫自动识别主要依赖关键点的局限性,提出一种基于白蚁分区的微方向感知的识别方法。使用分区策略细化目标,间接增加形态差异显著性。使用旋转矩形表征识别单元,保证对姿态扭曲的更精确感知,矩形框标注比点标注难度低且效率更高,同时包含更多的空间信息。将坐标位置和方向与多层特征直接关联,提高方法的目标定位能力。多阶段引入坐标注意力,结合跨层连接结合双支融合,提高特征融合的有效性。实验结果表明,本方法对干扰严重的白蚁图像具有更好准确性和鲁棒性,特别是前胸背板指标结果的低误差,进一步验证了本文方法对小目标的微小方向的精确感知。本文成果用于形态分析,提取的身躯分块,为探索类型高相关的微观指标提供了可能性,此外本方法对于其他类型昆虫图像同样具有广泛的应用潜力。

由于目前数据均为室内场景下拍色,背景相对单一,造成训练出的本方法的场景理解能力有限,同时当图像中存在异常姿态如仰或侧卧等造成目标遮挡,识别时会因空间信息缺失严重而漏检。未来工作中将收集更复杂光照和背景的室外拍摄图像,更多类型的白蚁图像,以及其他种属差异较大的昆虫图像,进一步验证和提升现有方法的泛化性能。此外为进一步改善目前矩形标记效率,后续将探索基于少量矩形的自动标注方法。

## 参考文献:

- [1] 黄复生,朱世模,平正明,等. 中国动物志(昆虫纲)[M]. 北京:科学出版社,2000:1-961.  
HUANG Fusheng, ZHU Shimo, PING Zhengming, et al. Fauna sinica (insecta) [M]. Beijing: Science Press, 2000:1-961.
- [2] 白明,杨星科. 三维几何形态学概述及其在昆虫学中的应用[J]. 昆虫学报,2014,57(9):1105-1111.  
BAI Ming, YANG Xingke. A review of three-dimensional (3D) geo-metric morphometrics and its application in entomology [J]. Acta Entomologica Sinica, 2014, 57(9):1105-1111.
- [3] HOANG H N, HAI B H, PHUONG H L, et al. A lightweight keypoint matching framework for insect wing morphometric landmark detection[J]. Ecological Informatics, 2022, 70:101694.
- [4] JOÃO P R, WALTER G, ALICE M P. Automatic wing geometric morphometrics classification of honey bee (apis mellifera) subspecies using deep learning for detecting land-marks[J]. Big Data and Cognitive Computing, 2022, 6(3):70-70.
- [5] WANG Zejun, ZHANG Shihao, CHEN Lijiao, et al. Microscopic insect pest detection in tea plantations; improved YOLOv8 model based on deep learning[J]. Agriculture, 2024, 14(10):1739.
- [6] BERECIARTUA-PÉREZ A, GOMEZ L, PICON A, et al. Insect counting through deep learning-based density maps estimation[J]. Computers and Electronics in Agriculture, 2022, 197:106933.
- [7] BUSCHBACHER K, AHRENS D, ESPELAND M, et al. Image-based species identification of wild bees using convolutional neural networks[J]. Ecological Informatics, 2020, 55:101017.
- [8] BADGUJAR C M, ARMSTRONG P R, GERKEN A R, et al. Identifying common stored product insects using automated deep learning methods[J]. Journal of Stored Products Research, 2023, 103:102166.
- [9] VENEGAS P, CALDERON F, RIOFRÍO D, et al. Automatic ladybird beetle detection using deep-learning models[J]. PLoS One, 2021, 16(6):e0253027.
- [10] TETILA E C, MACHADO B B, MENEZES G V, et al. A deep-learning approach for automatic counting of soybean insect pests[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(10):1837-1841.
- [11] 唐灿,唐亮贵,刘波. 图像特征检测与匹配方法研究综述[J]. 南京信息工程大学学报(自然科学版),2020,12(3):261-273.  
TANG Can, TANG Lianggui, LIU Bo. A survey of image feature detection and matching methods[J]. Journal of Nanjing University of Information Science and Technology (Natural Science Edition), 2020, 12(3):261-273.
- [12] 江铁,朱桂斌,孙奥,等. 特征点提取算法性能分析研究[J]. 科学技术与工程,2012,12(30):7924-7930.  
JIANG Tie, ZHU Guibin, SUN Ao, et al. Performance analysis of feature point detectors[J]. Science Technology and Engineering, 2012, 12(30):7924-7930.
- [13] YANG Jieren, ZHANG xinying, LUO Peng. A summary of feature point detection based on image mosaics[J]. Electronic Test, 2021(6):53-54.
- [14] LE V, BEURTON-AIMAR M, ZEMMARI A, et al. Automated land-marking for insects morphometric analysis using deep neural networks[J]. Ecological Informatics, 2020, 60:101175.
- [15] GELDENHUYS D S, JOSIAS S, BRINK W, et al. Deep learning approaches to landmark detection in tsetse wing images[J]. PLOS Computational Biology, 2023, 19(6):e1011194.
- [16] 安胜彪,娄慧儒,陈书旺,等. 基于深度学习的旋转目标检测方法研究进展[J]. 电子测量技术,2021,44(21):168-178.  
AN Shengbiao, LOU Huiru, CHEN Shuwang, et al. Research progress of rotating target detection methods based on deep learning[J]. Electronic Measurement Technology, 2021, 44(21):168-178.
- [17] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9):1627-1645.
- [18] 陈天鹏,胡建文. 基于深度学习的遥感图像旋转目标检测研究综述[J]. 计算机应用研究,2024,41(2):329-340.  
CHEN Tianpeng, HU Jianwen. Overview of oriented object detection based on deep learning in remote sensing [J]. Application Research of Computers, 2024, 41(2):329-340.
- [19] LONG Wen, YU Cheng, YI Fang, et al. A comprehensive survey of oriented object detection in remote sensing images[J]. Expert Systems with Applications, 2023, 224:16-26.
- [20] 王旭,吴艳霞,张雪,等. 计算机视觉下的旋转目标检测研究综述[J]. 计算机科学,2023,50(8):79-92.  
WANG Xiu, WU Yanxia, ZHANG Xue, et al. Survey of rotating object detection research in computer vision[J]. Computer Science, 2023, 50(8):79-92.
- [21] YUAN Shuai, QIN Hanlin, YAN Xiang, et al. Scrtansnet: spatial-channel cross transformer network for infrared small target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62(10):1-15.