

DOI:10.19651/j.cnki.emt.2518333

# 基于改进 YOLOv11n 的通航飞机 蒙皮表面损伤检测算法\*

夏正洪<sup>1</sup> 钟吉飞<sup>1</sup> 张军<sup>2</sup> 赵亮<sup>2</sup>

(1. 中国民用航空飞行学院空中交通管理学院 广汉 618307; 2. 中国民用航空飞行学院广汉分院 广汉 618307)

**摘要:** 针对通航飞机蒙皮表面损伤检测智能化水平不足的问题,提出了一种基于改进 YOLOv11n 的通航飞机蒙皮表面损伤检测算法。首先,替换 Adown 下采样机制构建多尺度特征融合架构,通过跨层级特征交互与轻量化核设计实现冗余信息动态压缩,降低算法参数数量与计算复杂度;其次,设计 DySample 动态上采样策略,通过可变卷积核形变感知与多任务梯度协同优化,提升模型在不同场景下的泛化能力;再者,引入 FASSHead 特征聚合检测头,通过渐进式语义融合与边缘感知约束,提升算法对复杂损伤区域的识别能力;最后,增加 P2 小目标检测层,在浅层网络嵌入高分辨率检测分支,提升对小目标及细节损伤的捕捉能力。最终,通过自主构建的通航蒙皮表面损伤数据集对改进算法效果进行验证。结果表明:改进算法精确率达到 87.4%,召回率达到 80.4%,mAP 值达到 86.6%。相较于基准模型 YOLOv11n 分别提升了 2.0%、9.4%、6.7%,显著提升了蒙皮表面损伤的检测性能,为通航飞机智能化检测维修体系奠定理论基础。

**关键词:** 目标检测;飞行安全;通用航空;蒙皮损伤;YOLOv11n

**中图分类号:** TP391;TN919.5 **文献标识码:** A **国家标准学科分类代码:** 580.60

## Aircraft skin surface damage detection algorithm for general aviation based on enhanced YOLOv11n

Xia Zhenghong<sup>1</sup> Zhong Jifei<sup>1</sup> Zhang Jun<sup>2</sup> Zhao Liang<sup>2</sup>

(1. College of Air Traffic Management, Civil Aviation Flight University of China, Guanghan 618307, China;

2. Guanghan Branch, Civil Aviation Flight University of China, Guanghan 618307, China)

**Abstract:** To address the insufficient intelligent detection of surface damage on general aviation aircraft skins, an improved YOLOv11n-based detection algorithm is proposed. Firstly, the Adown downsampling mechanism is replaced to construct a multi-scale feature fusion architecture, achieving dynamic compression of redundant information through cross-level feature interaction and lightweight kernel design, thereby reducing model parameters and computational complexity. Secondly, a DySample dynamic upsampling strategy is designed, enhancing the model's generalization across different scenarios via variable convolutional kernel deformation perception and multi-task gradient collaborative optimization. Furthermore, the FASSHead feature aggregation module is introduced, improving the algorithm's recognition capability for complex damage areas through progressive semantic fusion and edge-aware constraints. Finally, a P2 small object detection layer is added, embedding high-resolution detection branches in shallow networks to enhance the capture of small objects and detailed damages. The improved algorithm was validated using a self-built dataset of general aviation skin surface damages. Results show that the precision reached 87.4%, recall reached 80.4%, and mAP attained 86.6%. Compared with the baseline model YOLOv11n, these metrics improved by 2.0%, 9.4% and 6.7% respectively, significantly enhancing the detection performance of skin surface damage and laying a theoretical foundation for an intelligent detection and maintenance system for general aviation aircraft.

**Keywords:** object detection; flight safety; general aviation; skin damage; YOLOv11n

## 0 引言

通用航空(general aviation, GA)指的是除商业航空运

输之外的所有民用航空活动的总称。通航作为航空业的重要组成部分,在促进经济发展、提高公共服务水平等方面发挥着重要作用。然而,随着飞行小时数的增加、外界环境等

收稿日期:2025-03-12

\* 基金项目:国家重点研发计划(2024YFC3014400)、四川省重点研发计划项目(2024YFTX0078)、四川省科技计划资助(2023NSFSC0753)和中央高校基本科研经费(25CAFUC10036, 25CAFUC03105)项目资助

因素,通航飞机蒙皮表面不可避免地会出现裂纹、凹痕、脱落、划痕及腐蚀等损伤情况<sup>[1]</sup>,这些损伤若未能得到及时有效的检测和评估,将直接威胁到飞机的结构安全性和飞行性能。目前,通航飞机蒙皮表面损伤的检测工作仍然主要依赖于机务人员的目视检测,不仅效率低下、劳动强度大,而且检测结果的准确性主观性强<sup>[2]</sup>。因此,探索更加科学、高效且精确的蒙皮表面损伤检测方法已成为通航维修和检测领域亟待解决的问题。

目前,飞机蒙皮损伤检测技术主要有无损检测、自动化检测和基于深度学习检测等。无损检测技术包含目视、超声和红外检测等方法,其检测效率低、成本高<sup>[3]</sup>;自动化检测技术包含爬壁机器人和无人机检测等方法,其检测环境适应性受限、稳定性不足<sup>[4]</sup>。近年来,随着深度学习的发展,基于图像的目标检测方法逐渐成为研究热点,这些检测方法主要分为两阶段检测和单阶段检测两类。两阶段检测模型有Faster R-CNN<sup>[5]</sup>、Mask R-CNN<sup>[6]</sup>和Mask Scoring R-CNN<sup>[7]</sup>等,这类方法通常计算复杂度较高,资源消耗较大<sup>[8]</sup>;相比之下,单阶段检测方法具有高效性、实时性和多尺度特征利用等优势。典型的单阶段检测模型有SSD<sup>[9]</sup>、RetinaNet<sup>[10]</sup>和YOLO<sup>[11]</sup>等。

YOLO系列模型通过单次前向传播即可完成从输入图像到目标类别和边界框预测的全过程<sup>[12]</sup>。随着YOLO版本不断更新迭代,性能与功能上实现了显著突破,相较前几代产品,YOLOv11通过多尺度特征优化与高效架构设计,实现参数精简、多任务高精度及跨平台部署。这些特性使得蒙皮表面损伤检测技术极大增强了检测的准确性和处理速度,但蒙皮表面损伤检测技术主要应用于大型民用航空运输飞机,现有运输飞机蒙皮检测技术难以直接应用于通航飞机,主要原因是通航飞机蒙皮损伤以低空高频次训练飞行导致的冲击擦痕为主,与运输机疲劳裂纹类型差异显著;且通航飞机日均起降频次高、检修周期短,传统检测流程耗时过长,无法匹配高频次快速检修需求及复合材料差异化的结构特性。

因此,本文提出一种基于改进YOLOv11n的通航飞机蒙皮表面损伤检测算法。在骨干网络轻量化卷积设计降低计算复杂度,颈部网络构建多尺度特征融合架构并引入动态上采样策略增强跨层级特征交互,检测头设计渐进式语义融合与边缘约束模块,同时在浅层网络嵌入高分辨率检测分支提升小目标与细节损伤识别能力。以期实现对飞机蒙皮表面损伤的高效、精准识别与定位,从而提升通航飞行安全水平。

## 1 改进的YOLOv11n算法

YOLOv11n采用三级模块化架构设计,由特征提取骨干网络、特征融合颈部网络及检测头构成系统性检测框架。骨干网络提取图像特征,生成语义特征信息,为后续处理奠定基础。颈部网络融合多尺度特征图,增强特征质量,提升

模型性能。检测头识别、定位目标,确保输出准确可靠。

通航飞机蒙皮表面损伤分布具有多尺度、无规律性及背景杂乱等特点,尽管YOLOv11n提升了目标检测能力,但传统单尺度卷积难以有效捕捉多形态损伤特征,跨层级特征融合机制对杂乱目标的语义关联性不足,检测头对不规则损伤的定位精度受限。因此,为提高模型对复杂蒙皮表面损伤的检测能力,本文从骨干网络、颈部网络与检测头三方面对YOLOv11n进行改进,改进网络结构如图1所示。

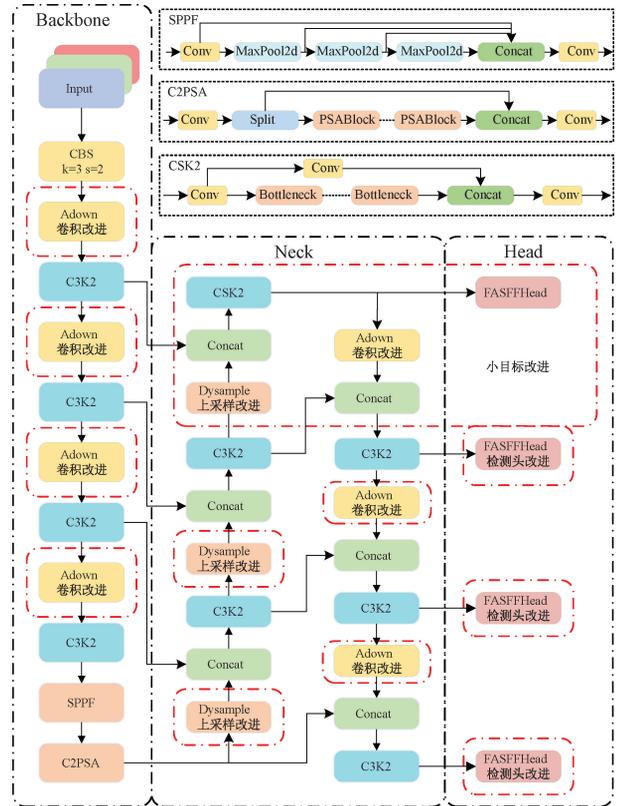


图1 改进YOLOv11n算法的网络结构

Fig. 1 Network architecture of the improved YOLOv11n algorithm

### 1.1 替换轻量化Adown下采样

传统的下采样方法,如标准卷积操作,在缩减特征图尺寸的过程中往往会丢失大量细节信息,这对小目标检测尤为不利。因此,替换为轻量化的Adown模块可以显著提升细节保留能力和检测精度,同时减少模型的计算量和参数量。Adown在多路径特征融合方面,通过融合平均池化和最大池化,有效地保留了不同尺度的特征信息,增强了模型对复杂特征的理解能力。

如图2所示,在卷积操作优化上,Adown主要依赖于 $3 \times 3$ 的卷积层,同时移除 $1 \times 1$ 卷积层,从而减少了特征冗余并提升了计算效率,确保关键特征的有效提取。此外,Adown模块具备高度的可学习性和自适应能力,能够根据具体的数据场景动态调整参数设置,使其更好地应对多样化任务需求,增强了在不同应用场景中的灵活性和鲁棒性。

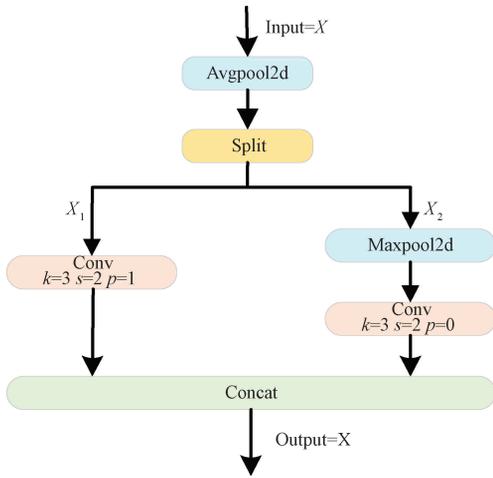


图 2 ADown 结构  
Fig. 2 Structure of ADown

1.2 替换轻量化的 DySample 上采样

DySample<sup>[13]</sup> 是一种超轻量高效动态上采样模块,摆脱了传统动态卷积与固定插值局限,回归到上采样的核心点采样。通过调整每一个上采样点的位置,让模型可以根据输入特征图的语义信息,灵活选取最佳采样位置。极大地提高了细节特征的恢复精度,尤其是在捕捉小目标的边缘和纹理方面表现卓越,实现了更加精确和细致的图像重建效果。

当给定输入特征图  $X$  和上采样比例  $s$ , 首先利用一个线性投影层生成偏移量  $O$ 。这些偏移量决定了每个像素位置上的位移程度,进而影响最终上采样结果的细节和清晰度。接着,通过像素重排技术将偏移量调整为适合的每个上采样点的水平和垂直偏移形式,即转换为  $2 \times sH \times sW$  的格式,如图 3(a)、(b) 所示。

原始规则采样网格 ( $G \in R^{2 \times sH \times sW}$ ) 的坐标定义如式(1)所示。

$$G_{i,j} = \left( \frac{i+0.5}{sH} \times 2 - 1, \frac{j+0.5}{sW} \times 2 - 1 \right) \quad (1)$$

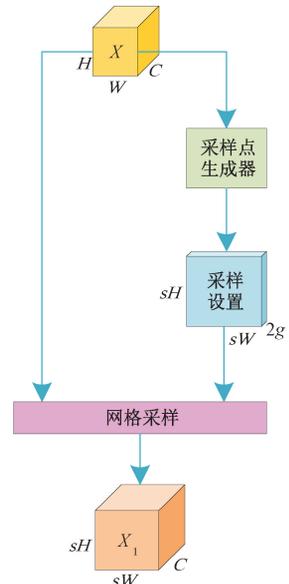
式(2)表示在未应用任何偏移前,采样网格中各点的初始位置。为了确保采样过程中的平滑过渡并减少伪影的产生,偏移量范围由静态、动态因子进行控制,将偏移量  $O$  叠加到原始网格  $G$  上,从而生成动态采样网格  $S$ 。

$$S = G + O \Rightarrow S_{i,j} = (G_{i,j}^x + \Delta x_{i,j}, G_{i,j}^y + \Delta y_{i,j}) \quad (2)$$

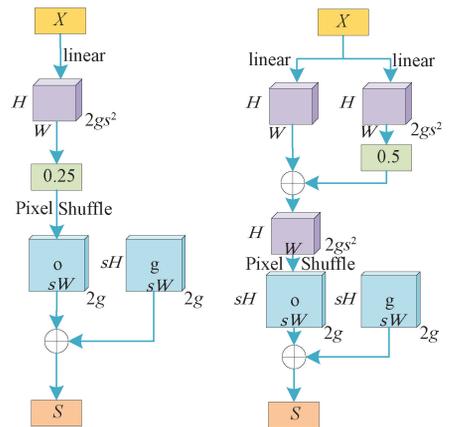
使得每个上采样点的精确位置得以确定。最后,采用 PyTorch 提供的 grid\_sample 函数对连续插值后的特征图进行重采样,如式(3)所示,以生成高分辨率特征图 ( $Y \in R^{C \times sH \times sW}$ )。

$$Y = \text{grid\_sample}(X, S) \quad (3)$$

此过程无需依赖定制的 CUDA 包,完全依靠内置函数实现,保证了算法的跨平台兼容性和易用性。不仅简化了实现流程,还显著提升了上采样操作的效果,使得处理后的图像更加细腻真实。



(a) 动态上采样  
(a) Dynamic upsampling



(b) 动态上采样中的采样点生成器  
(b) Sampling point generator for dynamic upsampling

图 3 DySample 结构

Fig. 3 Structure of DySample

1.3 替换 FASFFHead 改进的检测头

在目标检测任务中,模型需要有效地处理各种尺度的对象,但不同层级特征图之间的尺度不一致往往成为性能瓶颈。为解决这一问题,通过巧妙地将 ASFF<sup>[14]</sup> 集成到检测头部分,模型能够显著提升对不同尺度对象的识别和处理能力。不仅缓解了尺度不一致带来的问题,还大幅度提高了整体检测性能。

在 FASFFHead 模块中,如图 4 所示。L-1、L-2 和 L-3 代表不同分辨率的特征图。通过自适应尺度特征融合机制,特征图被融合为 FASFF-1、FASFF-2 和 FASFF-3。生成 FASFF-1 时,先对 L-3 进行  $3 \times 3$  最大池化提取关键信息,再通过  $3 \times 3$  卷积,同时对 L-2 使用  $3 \times 3$  卷积匹配维度与表达。生成 FASFF-2 时,L-3 经过  $3 \times 3$  卷积调整维度,L-1 则通过  $1 \times 1$  卷积提取特征并放大两倍分辨率以匹配

L-3。对于FASFF-3,L-2经 $1\times 1$ 卷积调整维度后分辨率翻倍,L-1也通过 $1\times 1$ 卷积后分辨率放大四倍,确保二者特征在尺度和维度上一致。

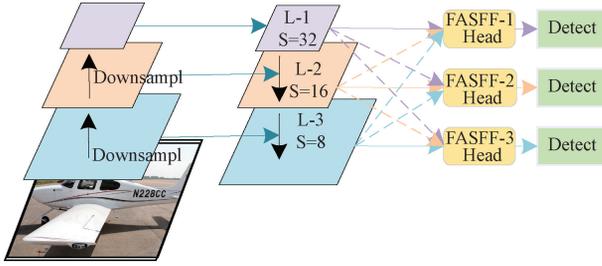


图4 FASFFHead结构

Fig. 4 Structure of FASFFHead

在自适应尺度特征融合ASFF中,以FASFF-3为例,分别从层级L-1、L-2和L-3获取的特征表示为 $x_1$ 、 $x_2$ 和 $x_3$ 。为了生成融合后的特征FASFF-3,这些特征首先各自乘以相应的权重系数 $\alpha_3$ 、 $\beta_3$ 和 $\gamma_3$ ,如式(4)所示,然后进行相加操作。使得权重系数是通过每个层级的特征图经过调整大小处理后,再经由 $1\times 1$ 卷积核变换得到。

$$y_i^l = \alpha_i^l \cdot x_1^{1+l} + \beta_i^l \cdot x_2^{2+l} + \gamma_i^l \cdot x_3^{3+l} \quad (4)$$

为了相加融合不同层级的特征,需要先统一它们的尺寸和通道数,通常通过上采样或下采样来实现。权重参数 $\alpha$ 、 $\beta$ 和 $\gamma$ 是通过调整大小后的特征图应用 $1\times 1$ 卷积得到,随后被拼接并经过softmax处理,确保它们的值在 $[0,1]$ 范围内总和为1,以合理分配各特征图的贡献比例,式(5)所示。

$$\alpha_i^l = \frac{e^{\lambda_{\alpha_i}^l}}{e^{\lambda_{\alpha_i}^l} + e^{\lambda_{\beta_i}^l} + e^{\lambda_{\gamma_i}^l}} \quad (5)$$

#### 1.4 增加P2小目标检测层

在YOLOv11n的原有架构中,目标检测层基于P3、P4、P5三个特征层,分别针对小、中、大型目标进行优化。为了进一步提升对小尺寸目标的检测能力,引入了P2检测层,使得网络能够在4个不同的下采样尺度上进行预测<sup>[15]</sup>。P2层对应的特征图分辨率为 $160\times 160$ ,其较小的感受野能够捕捉更为细微的目标细节,有效减少小目标的漏检情况。

因通航蒙皮损伤分布具有多尺度、无规律性及小尺寸损伤等特点,将FASFFHead与新增的P2层结合后,通过ASFF模块,系统能够动态融合从P2~P5层的多尺度特征,在处理不同尺度对象的能力上有了显著提升,有效增强了小目标的特征表达能力。

## 2 实验过程与分析

### 2.1 实验环境

实验部署于64位Windows11操作系统,核心处理器为32vCPU Intel(R) Xeon(R) Platinum 8481C。图形处理

单元选用了NVIDIA GeForce RTX 4090D GPU,配备24 GB GDDR6显存,系统运行内存容量为80 GB。软件环境方面,实验基于Python 3.10.12编程语言,PyTorch深度学习框架版本为2.1.0,CUDA版本为11.8,训练参数如表1所示。

表1 训练参数设置

Table 1 Training parameter settings

参数	设置
输入图像尺寸	640×640
训练轮次	50
批量	32
初始学习率	0.001
动量因子	0.937
优化器	SGD

### 2.2 实验数据集

数据集的质量和规模对神经网络训练与评估至关重要。高质量、大规模的数据集使模型能够学习复杂特征,提升识别精度和泛化能力。因此,构建一个高质量的数据集极为关键,由于公开蒙皮表面损伤数据较少,为获取高质量的通航蒙皮表面损伤数据集,分别在中国民用航空飞行学院、广汉机场、广汉分院修理厂等多个场地进行采集,涵盖塞斯纳172R、TB-200、TB-20、奖状-CJ1、夏延III A等多机型。采集环境涵盖晴天、阴雨、不均匀光照等场景,以及正视、斜视、俯视等多检测视角。采用海康威视MV-CU013-A0GM工业相机采集,其分辨率为 $1280\text{ pixel}\times 1024\text{ pixel}$ 。累计收集到了3958张蒙皮损伤图片,涵盖了6种蒙皮表面损伤类型:裂纹、凹痕、铆钉脱落、蒙皮脱落、划痕和腐蚀,如图5(a)~(f)所示。共包含12089个标注标签,其比例分别为28%、15%、17%、18%、12%和10%。

为有效提升模型的泛化能力,规避模型对训练数据的过拟合问题,确保模型在复杂多变的实际应用场景中具有良好的适应性,本文借助数据增强技术<sup>[16]</sup>对初始数据集进行优化。通过颜色抖动、随机缩放、锐化、裁剪、翻转、平移、旋转以及噪声添加等多种数据增强操作。将原始的3958张图片扩充至23729张,数据增强处理后,各类损伤的比例为裂纹21%,凹痕17%,铆钉脱落15%,蒙皮脱落16%,划痕17%,以及腐蚀14%。极大地丰富了数据集的多样性和规模,为后续基于深度学习的通航蒙皮表面损伤识别模型的训练与研究提供了坚实的数据保障。

### 2.3 评价指标

为衡量模型在目标检测任务中的表现,本文采用评价指标有:精确率(precision, P)、召回率(recall, R)、参数量(Params)、计算量(GFLOPs)、平均精度(average precision, AP)、平均精确度均值(mean average precision, mAP),计算公式如式(6)~(10)所示。

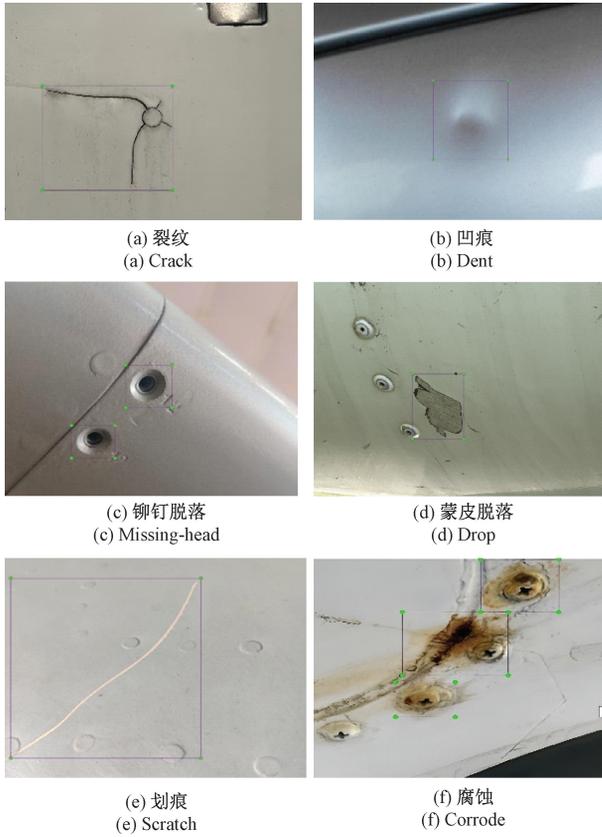


图 5 通航飞机蒙皮表面损伤类别实物图

Fig. 5 Categories of surface damage on general aviation aircraft skin

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$R = \frac{TP}{TP + FN} \tag{7}$$

$$AP = \int_0^1 P(R) dR \tag{8}$$

$$mAP = \frac{\sum_{m=1}^M AP}{M} \tag{9}$$

$$FPS = \frac{N(p)}{T(p)} \tag{10}$$

式中： $TP$  为正确分类的正类样本数量，即实际为正类且被模型预测为正类的情况； $FP$  为误判的正类样本数，即实际为负类却被错误预测为正类的实例； $FN$  为漏检的正类样本数，即实际为正类但被模型错误归类为负类的数量； $M$  为数据集中包含的类别总数； $N(p)$  为算法处理的总图像数量； $T(p)$  表示单张图像从预处理到结果输出的完整处理耗时。

### 3 实验结果与分析

#### 3.1 消融实验

为了分析各改进模块对 YOLOv11n 算法在通航飞机蒙皮表面损伤检测性能上的提升作用，设计了 8 组消融实验。先以 YOLOv11n 为基准模型，依次添加小目标检测层 P2、替换 FASSHead 检测头、引入 Adown 下采样以及 Dysample 上采样。通过逐步将这些改进模块融入 YOLOv11n 算法，最终获得的试验结果如表 2 所示。

表 2 消融试验结果

Table 2 Results of ablation experiment

模型	P2	FASSHead	Adown	Dysample	P/%	R/%	mAP/%	FPS/fps	Params/ $10^6$	GFLOPs/M
1	×	×	×	×	85.4	71.0	79.9	136.5	2.6	6.4
2	√	×	×	×	84.3	74.8	82.3	109.9	2.9	12.5
3	×	√	×	×	83.7	73.8	80.6	118.4	4.0	8.6
4	×	×	√	×	86.5	74.6	81.9	<b>146.8</b>	<b>2.1</b>	<b>5.3</b>
5	×	×	×	√	87.3	72.2	81.2	139.6	2.6	6.5
6	√	√	×	×	84.7	75.9	83.1	97.8	4.1	13.4
7	√	√	√	×	87.1	78.6	85.8	119.0	3.7	12.3
8	√	√	√	√	<b>87.4</b>	<b>80.4</b>	<b>86.6</b>	125.1	3.6	12.3

通过对实验结果分析，引入 P2 小目标检测层后，模型的 P、R 和 mAP@0.5 分别达到 84.3%、74.8% 和 82.3%，与基础模型相比，mAP@0.5 提升了 2.4%。引入 FASSHead 使 P、R 和 mAP@0.5 分别达到 83.7%、73.8% 和 80.6%，mAP@0.5 提升了 0.7%。Adown 模块的引入使 P、R 和 mAP@0.5 分别达到 86.5%、74.6% 和 81.9%，mAP@0.5 提升了 2.0%。Dysample 模块的引入使 P、R 和 mAP@0.5 分别达到 87.3%、72.2% 和 81.2%，

mAP@0.5 提升了 1.3%。

综合改进后的模型在同时引入 P2 小目标检测层、FASSHead、Adown 和 Dysample 模块后，P、R 和 mAP@0.5 分别达到 87.4%、80.4% 和 86.6%，与基础模型相比，mAP@0.5 提升了 6.7%。同时，模型帧数、参数量和计算量分别为 125.1 fps、 $3.6 \times 10^6$  和  $12.3 \times 10^9$ ，表明在不显著增加模型复杂度的情况下，显著提升了模型的检测性能。这些改进为多尺度检测任务提供了更为高效和精准的解

决方案。

### 3.2 对比实验

为了检验改进模型的实际效能,实验采用多基线对比策略,让改进模型分别与YOLOv11n、YOLOv10n、YOLOv9t及YOLOv8n进行对比。选择这些模型进行对比的原因在于它们代表了YOLO系列算法在不同参数量和计算复杂度下的性能表现,能够全面评估本文算法在P、R和mAP@0.5等方面的优劣。

表3展示了各模型的对比结果,图6(a)~(d)分别展示了P、R、mAP@0.5和mAP@0.5:0.95值模型改进效果对比图。本文提出的改进算法在多个评价指标上均表现出色。在P和R方面,本文算法分别达到了87.4%和80.4%,显著优于其他YOLO算法。mAP@0.5也达到了86.6%,远高于其他算法。然而,本文算法的参数量和计算量相对较高。尽管如此,其性能优势明显,适用于对R和mAP@0.5值有较高要求的应用场景。

表3 对比试验结果

Table 3 Compare experimental results

算法	P/%	R/%	mAP/%	FPS/fps	Params/ $10^6$	GFLOPs/M
YOLOv11n	85.4	71.0	79.9	136.5	2.6	<b>6.4</b>
YOLOv10n	82.7	69.6	77.9	118.9	2.7	8.4
YOLOv9t	82.0	65.1	73.8	<b>145.4</b>	<b>1.8</b>	6.7
YOLOv8n	85.5	70.2	78.6	121.6	2.7	6.9
本文	<b>87.4</b>	<b>80.4</b>	<b>86.6</b>	125.1	3.6	12.3

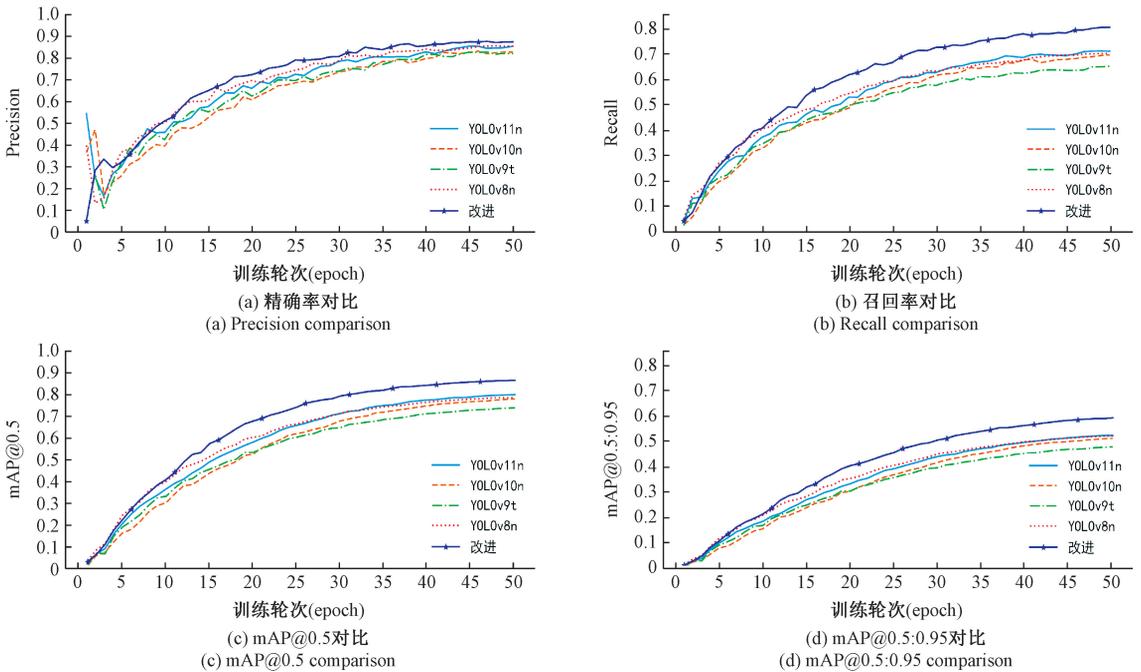


图6 模型改进效果对比

Fig. 6 Comparison of model improvement effects

### 3.3 实验检测结果可视化分析

为直观评估改进算法在蒙皮表面缺陷检测中的性能提升效果,对比了原始YOLOv11n算法与改进算法的检测结果,如图7(a)、(b)所示,图中各矩形框对应检测出的飞机蒙皮缺陷区域,且每个缺陷区域上方均明确标注了相应的缺陷类别与置信度数值。经图像对比分析,改进后的模型性能更优,定位损伤目标时更精准,对边界框位置与尺

寸的预测也更准确,使损伤定位和分类结果更贴合实际。

面对尺寸较小的损伤目标时,改进后的模型依然能够保持较高的检测精度。在实际应用中具有重要意义,因为小型缺陷往往难以被肉眼发现,但它们可能会对结构的安全性造成严重影响。因此,在不降低精度的前提下有效检测小尺寸缺陷的算法,大大提升了整体检测系统的实用性。



(a) 改进前检测结果  
(a) Detection performance before optimization



(b) 改进后检测结果  
(b) Detection performance after optimization

图 7 检测结果可视化对比

Fig. 7 Visual comparison of detection result

## 4 结 论

本文提出了一种基于改进的 YOLOv11n 通航飞机蒙皮表面损伤检测算法,针对蒙皮表面损伤多尺度、无规律性特征,从 P2、FASSHead、Adown 和 Dysample 四个维度改进算法架构,改进后的算法显著提升了检测精度和效率,更加适应小尺寸损伤检测,增强实时性和抗干扰能力,使鲁棒性更强。

通过消融实验验证,本文算法相较于基线模型在检测精确率、召回率、mAP 值分别提升了 2.0%、9.4%、6.7%,帧率为 125.1 fps,参数量为  $3.6 \times 10^6$ ,计算量为  $12.3 \times 10^9$ 。尽管改进后的算法在帧率上有所下降、参数量和计算量上有所增加,但其在检测精度大幅度提升,更加适用于实际应用中通航飞机蒙皮表面损伤的精准检测。下一步将研究复杂天气(如雨天/雾天)影响下的通航飞机蒙皮表面损伤检测方法。

## 参考文献

- [1] 刘芳,夏桂锁,温志辉,等. 飞机蒙皮缺陷检测的现状与展望[J]. 航空制造技术, 2021, 64(Z2):39-50.  
LIU F, XIA G S, WEN ZH H, et al. Current status and prospects of aircraft skin defect detection [J]. Aeronautical Manufacturing Technology, 2021, 64(Z2): 39-50.
- [2] 吴军,石改琴,卢帅员,等. 采用无人机视觉的飞机蒙皮损伤智能检测方法[J]. 中国测试, 2021, 47(11):119-126.  
WU J, SHI G Q, LU SH Y, et al. An intelligent detection method for aircraft skin damage using UAV

vision[J]. China Measurement & Test, 2021, 47(11): 119-126.

- [3] 于筱然. 浅析各种无损检测技术的优缺点[J]. 电子测试, 2019(19):86-88.  
YU X R. Analysis of advantages and disadvantages of non-destructive testing technologies [J]. Electronic Test, 2019(19):86-88.
- [4] 董竞莹. 基于无人机航拍的大型飞机表面缺陷检测技术[D]. 南京:南京航空航天大学, 2021.  
DONG J X. Surface defect detection technology for large aircraft based on UAV aerial photography[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2021.
- [5] 郁岩,齐继阳. 改进 Faster R-CNN 的微型扁平电机 FPC 表面焊点缺陷检测[J]. 电子测量技术, 2022, 45(7):146-151.  
YU Y, QI J Y. Improved faster R-CNN for FPC surface solder joint defect detection in micro flat motors [J]. Electronic Measurement Technology, 2022, 45(7):146-151.
- [6] DANIELCZUK M, MATL M, GUPTA S, et al. Segmenting unknown 3D objects from real depth images using mask R-CNN trained on synthetic point clouds[J]. ArXiv preprint arXiv:1809.05825, 2018.
- [7] ZHAO J H, LI CH H, YONG CH G, et al. Mask scoring R-CNN [J]. ArXiv preprint arXiv: 1903.00241, 2019.
- [8] 周晓彦,王珂,李凌燕. 基于深度学习的目标检测算法综述[J]. 电子测量技术, 2017, 40(11):89-93.  
ZHOU X Y, WANG K, LI L Y. A survey of object detection algorithms based on deep learning [J]. Electronic Measurement Technology, 2017, 40(11): 89-93.
- [9] WEI L, ANGUEVOV D, ERHAN D, et al. SSD: Single shot multi-box detector [J]. ArXiv preprint arXiv:1512.02325, 2015.
- [10] 吴正平,张程鹏,雷帮军,等. 改进 RetinaNet 模型的小目标检测[J]. 计算机仿真, 2023, 40(2):181-189.  
WU ZH P, ZHANG CH P, LEI B J, et al. Small target detection with improved RetinaNet model[J]. Computer Simulation, 2023, 40(2):181-189.
- [11] REDMON J, DIVVALA K S, GIRSHICK B R, et al. You only look once: Unified, real-time object detection [J]. ArXiv preprint arXiv:1506.02640, 2015.
- [12] 邵延华,张铎,楚红雨,等. 基于深度学习的 YOLO 目标检测综述[J]. 电子与信息学报, 2022, 44(10): 3697-3708.  
SHAO Y H, ZHANG D, CHU H Y, et al. A survey of

- YOLO-based object detection using deep learning [J]. Journal of Electronics & Information Technology, 2022, 44(10):3697-3708.
- [13] ZHEN Y L, BEN SH Y, YA N ZH. LD-YOLO: A lightweight dynamic forest fire and smoke detection model with dysample and spatial context awareness module[J]. Forests, 2024, 15(9):1630.
- [14] SI Y SH, XING ZH, WEN J Y, et al. An improved UAV target detection algorithm based on ASFF-YOLOv5s [ J ]. Mathematical Biosciences and Engineering, 2023, 20(6):10773-10789.
- [15] 雷帮军, 余翱, 吴正平, 等. 基于位置感知和跨层特征融合的航拍小目标检测算法[J]. 电子测量技术, 2024, 47(5):112-123.
- LEI B J, YU AO, WU ZH P, et al. Aerial small target detection algorithm based on position awareness and cross-layer feature fusion [ J ]. Electronic Measurement Technology, 2024, 47(5):112-123.
- [16] 杨锁荣, 杨洪朝, 申富饶, 等. 面向深度学习的图像数据增强综述[J]. 软件学报, 2025(3):1390-1412.
- YANG S R, YANG H CH, SHEN F R, et al. A survey on image data augmentation for deep learning[J]. Journal of Software, 2025(3):1390-1412.

### 作者简介

**夏正洪**, 硕士, 教授, 研究生导师, 主要研究方向为基于深度学习的航空运行安全风险评价。

E-mail: 66949827@qq.com

**钟吉飞**(通信作者), 硕士研究生, 主要研究方向为基于深度学习的目标检测算法。

E-mail: 2932352663@qq.com

**张军**, 硕士, 工程师, 主要研究方向为机务维修。

E-mail: Zhangjun@cafuc.edu.cn

**赵亮**, 硕士, 工程师, 主要研究方向为机务维修。

E-mail: Zhaoliang@cafuc.edu.cn