

杨凡, 张洁, 蒋安祥. 改进 YOLOv8n 的迷彩伪装目标检测算法[J]. 智能计算机与应用, 2025, 15(6): 7-14. DOI: 10. 20169/ j. issn. 2095-2163. 24122503

# 改进 YOLOv8n 的迷彩伪装目标检测算法

杨凡<sup>1</sup>, 张洁<sup>2</sup>, 蒋安祥<sup>3</sup>

(1 南京邮电大学 计算机学院, 南京 210023; 2 南京邮电大学 软件学院, 南京 210023;

3 南京邮电大学 网络空间安全学院, 南京 210023)

**摘要:** 军事伪装在战争中发挥着至关重要的作用。针对迷彩伪装检测难度大、实时性要求高以及现有的迷彩伪装检测算法计算量大、参数量多等问题, 本文提出了一种改进 YOLOv8n 的轻量化检测算法 YOLO-FCL。通过改进主干网络, 在原始的 C2f 网络中融合轻量化结构 PConv, 设计出 FC2f 网络, 显著降低了模型的参数和计算量; 此外, 为强化模型的特征提取能力, 引入 LSK 注意力机制, 根据不同的目标对背景环境的需求不同动态调整感受野大小。实验结果表明, 在参数量减少 23% 的前提下, YOLO-FCL 算法在公开的迷彩伪装数据集上取得了 95.6% 的平均精度 ( $mAP$ ) 和 91.5% 的召回率 ( $Recall$ ), 相较于当前研究成果有显著的提升。

**关键词:** 伪装; 迷彩伪装士兵; 目标检测; YOLOv8n 算法; 轻量化

中图分类号: TP391.41

文献标志码: A

文章编号: 2095-2163(2025)06-0007-08

## Improvement of the camouflage target detection algorithm of YOLOv8n

YANG Fan<sup>1</sup>, ZHANG Jie<sup>2</sup>, JIANG Anxiang<sup>3</sup>

(1 School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;

2 School of Software, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;

3 School of Cyberspace Security, Nanjing University of Posts and Telecommunications, Nanjing 210023, China )

**Abstract:** Military camouflage plays a crucial role in warfare. Aiming at the difficulties of camouflage detection, high real-time requirements, and large computation and large number of parameters of existing camouflage detection algorithms, this paper proposes a lightweight detection model YOLO-FCL based on YOLOv8n. By improving the backbone network and integrating the lightweight structure PConv into the original C2f network, the FC2f network is designed, which significantly reduces the model parameters and calculation amount. In addition, in order to enhance the feature extraction ability of the model, LSK attention mechanism is introduced to dynamically adjust the receptive field size according to the different demands of different targets on the background environment. Experimental results show that the YOLO-FCL algorithm achieves 95.6% average accuracy ( $mAP$ ) and Recall of 91.5% on the public camouflage data set with about 23% reduction in the number of parameters, which is significantly improved compared with the current research results.

**Key words:** disguise; camouflage soldiers; target detection; YOLOv8n algorithm; lightweight

## 0 引言

目前, 先进的人工智能技术已陆续应用到生活的诸多方面, 包括医疗、农业和军事等领域。在军事领域中, 先进的伪装技术被广泛应用, 战场环境的探测<sup>[1]</sup>以及军事目标的侦察显得更加困难。快速精准定位出战场环境当中隐藏的敌方士兵以及武器装

备, 对于把握战场情况、扭转战争态势极为重要。目标检测技术水平的不断提升使其在现代战场中已成为必不可少的一部分。

与一般显著性目标检测相比, 迷彩伪装目标<sup>[2]</sup>的检测、定位给科研工作者们带来了更大的挑战。由于迷彩伪装目标的纹理、颜色等完美融合于背景环境<sup>[3]</sup>, 使得检测变得尤为困难。当前, 基于深度

**基金项目:** 国家重点研发计划(2018YFB1500902); 国家自然科学基金青年基金(61902195)。

**作者简介:** 杨凡(1998—), 男, 硕士研究生, 主要研究方向: 目标检测; 蒋安祥(2000—), 男, 硕士研究生, 主要研究方向: 目标检测。

**通信作者:** 张洁(1981—), 女, 高级工程师, 硕士生导师, 主要研究方向: 图像处理, 目标检测。Email: zhangjie@njupt.edu.cn。

收稿日期: 2024-12-25

哈尔滨工业大学主办 ◆ 学术研究与应用

学习的方法利用卷积神经网络提取目标特征,并通过主动学习更深层次的特征信息,就不仅提高了检测的效果,还能够通过快速检测速度应对战场的瞬息变化。深度学习目标检测方法分为2类:双阶段(Two-Stage)和单阶段(One-Stage)目标检测算法。其中,双阶段算法通过区域生成网络首先生成候选区域,然后对这些区域进行分类和回归。代表算法有R-CNN<sup>[4]</sup>、Fast R-CNN<sup>[5]</sup>、Faster R-CNN<sup>[6]</sup>等。单阶段检测算法则直接对目标进行分类和回归。代表算法有YOLO算法<sup>[7]</sup>、SSD<sup>[8]</sup>、RetinaNet<sup>[9]</sup>等。尽管前者在精度上要优于后者,但带来的弊端是检测速度慢,难以适应真实战场环境中迅速、准确的要求。鉴于此,单阶段目标检测算法因其实时性而更适合快速且准确地定位敌军藏身之处。然而,由于迷彩伪装目标与背景的高融合程度,神经网络往往只能提取浅层特征,影响了检测结果。针对这一问题,研究人员通常在已有的目标检测算法上做出改进,通过提高网络提取特征的能力或者增大感受野来加强检测效果。Fan等学者<sup>[10]</sup>提出了模仿人类视觉机制的搜索识别网络SINet,取得了显著的成效。在此之后,王杨等学者<sup>[11]</sup>基于YOLOv5算法,结合SE和Triplet Attention机制设计特征提取网络,强化对目标的特征提取能力,并使用非对称卷积突出目标,有效提升了检测的效果。Zhang等学者<sup>[12]</sup>设计了跨层特征融合网络CFANet,通过挖掘不同层级特征的异同,有效地聚合主干网络产生的多层次、多尺度特征。Lyu等学者<sup>[13]</sup>结合概率衍生的不确定性和确定性衍生的边缘信息,提出UEDG架构,借助于边缘先验知识关注高度不确定区域,从而准确地检测隐藏的伪装目标。Yang等学者<sup>[14]</sup>从伪装机制的角度重新思考伪装目标检测任务,通过减轻显著对象的干扰信息和增强伪装对象与其背景之间的边界差异,破坏伪装条件,突出伪装目标的价值线索,取得了一定的成绩。以上方法虽然在一定程度上提升了检测的效果,但随之带来的是模型更大、参数量增加、网络层数的加深,导致检测速度变慢、模型不够轻量化等问题,以及无法很好地部署在移动设备上,比如无人机、飞行设备等,故仍有提升的空间。

为此,本文以YOLOv8n模型为基准,根据迷彩伪装目标的特点,以更轻的网络结构、更精准的检测效果为目标,提出YOLOv8-FCL迷彩伪装士兵检测方法,本文的主要工作与创新如下:

首先,为了减少网络层数,使模型轻量化,改进

YOLOv8n主干网络,使用FasterNet网络结构代替YOLOv8n原有的C2f网络,网络层数大大减少,检测速度更快。

其次,尽管FasterNet网络提高了检测速度,但随之带来的是检测精度的降低。通过融合C2f网络与FasterNet网络,综合两者优点,提出一种Faster\_C2f网络,在保证检测速度的情况下仍能提升检测精度。

最后,为了更好地提取目标的特征信息,从而准确地定位目标位置,通过在YOLOv8n特征提取网络中进行多种实验,对比在不同位置中加入多种注意力的检测效果,最终得出结论:在SPPF前加入LSK注意力机制效果最佳。通过动态调整感受野大小来增强特征提取的能力,更有效地解决了伪装场景下、目标与背景难以区分的问题。

## 1 YOLOv8n 算法

YOLOv8n算法是一个继承自YOLOv5的单阶段实时目标检测模型,两者出自同一个团队,是一款前沿的SOTA模型。鉴于YOLOv5版本的成功,YOLOv8的研发者对其做出一系列改进,引入许多新的功能,进一步提高了检测的效果,其模型结构如图1所示。YOLOv8主要由3部分组成,分别是Backbone主干网络、Neck颈部和Head检测头。骨干网络主要用于进行提取特征,对输入的图片进行一系列的卷积操作。在YOLOv8中,研发时保持了CSP的设计理念,并对CSPDarkNet53网络进行了改进。具体而言,YOLOv5中的C3模块被新的C2f模块取代,后者结合了C3模块的特点和YOLOv7中ELAN模块的设计思想,使得模型在轻量化的同时能够获取更丰富的梯度信息和特征。颈部采用FPN<sup>[15]</sup>和PAN<sup>[16]</sup>两种结构来融合不同层次的特征,从而有效地处理多尺度下的目标检测问题。FPN通过自顶向下的传递方式,强化底层特征图的语义信息;PAN则自底向上传递信息,增强顶层特征图的位置信息。通过两者结合后的特征,强化了模型对各种尺度目标的检测能力。与YOLOv5不同的是,移除了上采样阶段中的卷积结构。Head部分采用了YOLOX的解耦头设计,将分类和定位分离,进一步提升预测的精度,并且摒弃了先前的Anchor-Base,取而代之使用了Anchor-Free的思想。在损失函数方面,预测框边界回归任务使用DFL Loss (Distribution Focal Loss) 结合CIoU Loss (Complete Intersection over Union Loss) 作为分类损失。其中,

DFL 的计算公式如下:

$$DFL(S_i, S_{i+1}) = ((Y_{i+1} - Y) \log(S_i) + (y - y_i) (\log(S_{i+1}))) \quad (1)$$

其中,  $S_i, S_{i+1}$  表示  $Y_i, Y_{i+1}$  的一般分布。

尽管 YOLOv8 在轻量化和检测速度方面相比前版本有所提升,但在移动设备等资源受限的战场环

境中,模型仍需更快、更实时的性能。因此,对于需要实时响应的场景下,该模型仍有一定的改进空间,以满足轻量化的同时具备高检测精度。本文以 YOLOv8n 为基础,对其进行一系列改进,以适应迷彩伪装目标的实时检测。




图 1 YOLOv8n 网络结构图

Fig. 1 YOLOv8n network structure diagram

## 2 改进的 YOLOv8 算法

### 2.1 PConv 轻量化卷积块

FasterNet 卷积神经网络是一个突破性的轻量化卷积神经网络,旨在解决传统神经网络在计算复杂度和内存访问方面的瓶颈问题。在卷积运算中,频繁的内存访问和大量的冗余计算会降低效率。为此,FasterNet<sup>[17]</sup>引入了一种名为 Partial Convolution (PConv)的新型卷积模块,有效地减轻了上述问题,从而提升了计算的效率。

在标准卷积(Conv)操作中,通常将卷积核的通道数设定为与输入特征图相同,这导致了较高的内存占用和计算成本。PConv 针对此不足,提出了一种有效的特征提取方案。其核心在于仅在输入通道的部分区域执行常规卷积来提取特征,而不影响其他通道,维持输入输出特征图的通道数不变。其原理如图 2 所示。




图 2 PConv 卷积原理图

Fig. 2 Schematic diagram of PConv convolution

PConv 这一巧妙的设计大幅降低了浮点运算次数 (FLOPs) 和内存的使用量。对于标准卷积,输入为  $X \in R^{c \times h \times w}$ 、输出  $Y \in R^{c \times h \times w}$ , FLOPs 为:

$$h \times w \times k^2 \times c^2 \quad (2)$$

内存使用量为:

$$Conv_{mem} = h \times w \times 2c + k^2 \times c^2 \approx h \times w \times 2c \quad (3)$$

而对于 PConv, FLOPs 为:

$$h \times w \times k^2 \times c_p^2 \quad (4)$$

内存使用量为:



$$h \times w \times 2c_p + k^2 \times c_p^2 \approx h \times w \times 2c_p \quad (5)$$

其中,  $c$  和  $c_p$  表示通道的编号,  $h, w$  分别表示输入特征图的高度和宽度。由式(2)~(5)可得出结论:如果  $c_p/c = 1/4$ , 那么 PConv 的  $FLOPs$  仅为普通卷积的  $1/16$ , 内存访问量将是普通卷积的  $1/4$ 。如此显著的效率提升极大地加快了模型推理速度, 并提升了检测速度。

## 2.2 FC2f 模块

为了平衡在迷彩伪装目标上的检测速度与精度, 构建更加轻量级的 YOLOv8n 检测网络, 受到 FasterNet 网络中 PConv 模块的启发, 本研究在 YOLOv8n 中融合 PConv 模块低计算量和低内存使用量优势。在 YOLOv8n 网络中, 采用 CSPDarkNet53 作为特征提取网络, 用具有 2 个卷积的 CSP 瓶颈模块, 即 C2f 取代原来的 CSP 模块。采用 CSP 瓶颈模块 C2f 替代原有的 CSP 模块。C2f 模块源自 C3 模块和 YOLOv7 中 ELAN 模块的设计思想, 重点强调空间特征信息的保存, 通过一系列卷积层和池化层结构提取特征, 并采用梯度分流链接。其模块结构

如图 3(a) 所示。图 3(a) 中,  $n$  表示瓶颈块的个数。

尽管 C2f 增强了特征提取能力, 提高了检测的精度, 但其 BottleNeck 由 2 个连续的 CBS 结构组成, 每个 CBS 由标准卷积、归一化和激活函数构成, 这增加了参数量和计算复杂性。

因此, 本研究对 BottleNeck 部分进行改进以满足低参数量、低计算复杂度的要求。具体操作是构建一个轻量级的 BottleNeck 的模块, 命名为 FBlockNeck, 该模块由 1 个  $3 \times 3$  尺寸的 PConv 和 2 个  $1 \times 1$  尺寸的 Conv 组成, 在 PConv 和 Conv 之间建立残差链接以保证能够提取到种类足够丰富且多样化的特征。为了加速推理, 采用 ReLu 激活函数取代原 C2f 中的 SiLU 激活函数。FBlockNeck 模块通过减少卷积操作来降低参数量, 从而提升检测速度。通过此模块构建新的 C2f 模块被命名为 FC2f, 其结构如图 3(b) 所示。FC2f 模块结合了 C2f 的高效特征提取和 FBlockNeck 的低参数量优势, 在提升检测效果的同时减少了参数量。




图 3 C2f 与 FC2f 结构图

Fig. 3 Diagram of C2f and FC2f structure

## 2.3 LSK 注意力模块

迷彩伪装目标检测在复杂背景下, 如丛林、荒漠和雪地, 面临着特别的挑战, 即背景特征与目标特征高度相似, 使得目标与环境相融合, 难以分辨。针对此问题, 多种注意力机制被提出, 如致力于突出重点目标, 抑制环境当中的干扰因素的 SE<sup>[18]</sup> 注意力; 通过结合通道和空间两个维度, 与输入特征图做乘积以适应特征的 CBAM 注意力<sup>[19]</sup>; 再如为了减少通道信息和计算开销, 重塑通道致批次维度的 EMAttention<sup>[20]</sup> 等。对于伪装场景下, 伪装目标与周围背景难以区分, 使得模型难以聚焦感兴趣部分。LSK<sup>[21]</sup> 注意力机制通过动态调整感受野大小来增强特征提取的能力, 根据不同的目标对背景环境的需求不同, 自适应地调整感受野范围, 特别适合解决此场景带来的难题。

LSK Attention 的工作原理如图 4 所示。LSK

module 由 1 个大核卷积序列 (Large Kernel Convolutions) 和 1 个空间选择机制 (Spatial Kernel Selection Mechanism) 组成。为了适应不同目标对背景的需求不同, 本文提出一系列具有大核卷积序列并且持续扩张的 Depth-wise 卷积, 动态地构建了一个更大的感受野网络。具体来说, 假设序列中第  $n$  个 Depth-wise 的卷积核大小为  $k$ , 扩张率为  $d$ , 感受野为  $RF$ , 满足如下公式:

$$k_{n-1} \leq k_n; d_1 = 1, d_{n-1} < d_n \leq RF_{n-1} \quad (6)$$

$$RF_1 = k_1, RF_n = d_n(k_n - 1) + RF_{n-1} \quad (7)$$

通过式(6)、式(7)将一个大卷积核解耦为多个小卷积核序列, 生成的多个小卷积核对应多种不同大小的感受野, 便于适应不同场景目标的需求。同时, 相比原始的大核卷积, 这些解耦后的小卷积核效果更佳且参数量更少。




图 4 LSK Attention 的工作原理

Fig. 4 How LSK Attention works

为了从输入数据  $X$  的不同背景区域获取更加丰富的特征信息,采用一系列解耦的 Depth-Wise 卷积核:

$$U_0 = X, U_{n+1} = \tau_n^{\text{dw}}(u_n) \quad (8)$$

其中,  $\tau_n^{\text{dw}}(\cdot)$  表示卷积核为  $k_n$ 、扩张率为  $d_n$  的 Depth-Wise 卷积操作。假定由  $M$  个解耦的卷积核,则每个 Depth-Wise 卷积操作之后再经过 1 个  $1 \times 1$  的卷积  $\tau^{1 \times 1}$  进行空间向量的通道特征融合,得到结果  $U_n^-$ :

$$U_n^- = \tau_n^{1 \times 1}(U_n), \text{ for } n \text{ in } [1, M] \quad (9)$$

紧接着,基于空间选择机制,可以动态地选择适当的卷积核尺寸以适应不同的目标。

空间选择机制旨在对大卷积核序列解耦出的不同尺度的特征子图进行动态选择,以便模型更加关注于空间上的关键信息。首先,将来自于不同感受野的卷积核特征进行拼接:

$$U^- = [U_1^-; \dots; U_n^-] \quad (10)$$

其次,运用通道级的平均池化和最大池化提取

拼接好的  $U^-$  之间的空间关系:

$$SA_{\text{avg}} = \rho_{\text{avg}}(U^-), SA_{\text{max}} = \rho_{\text{max}}(U^-) \quad (11)$$

其中,  $SA_{\text{avg}}$  和  $SA_{\text{max}}$  分别表示平均池化和最大池化后的空间特征描述符。为了促进不同空间描述符信息的交互融合,利用  $\rho^{2-M}$  将空间池化特征进行拼接,转换这 2 个通道的池化特征为  $M$  个空间注意力特征图。研究用到的公式为:

$$SA^- = \rho^{2-M}([SA_{\text{avg}}; SA_{\text{max}}]) \quad (12)$$

接下来,对每一个空间注意力特征图  $SA^-$ ,使用 Sigmoid 激活函数获取每个解耦后的大卷积核所对应的空间选择特征  $SA_i^-$ 。将空间选择特征与大卷积核序列特征进行加权融合生成注意力特征  $Att$ ,最后将  $Att$  与输入特征  $X$  进行逐元素点积操作,生成最终注意力特征结果  $Y$ ,具体公式如下:

$$SA_i^- = \sigma(SA_i^-) \quad (13)$$

$$Att = \rho\left(\sum_{n=1}^M (SA_i^- \cdot U_n^-)\right) \quad (14)$$

$$Y = Att \cdot X \quad (15)$$

改进后的模型网络结构如图 5 所示。




图 5 改进后的网络结构图

Fig. 5 Diagram of improved network structure

3 实验结果与分析

3.1 数据集

本文的实验基于一种公开的迷彩伪装士兵数据集,此数据集包含了 5 种不同场景的伪装士兵,分别

是树林、雨林、荒漠、雪地以及开阔场地,共 33 种迷彩样式,包括俯身、蹲伏、战术卧倒、站立等多种姿态。整个数据集共 3 266 张图片,以 7.0 : 1.5 : 1.5 的比例划分为训练集、验证集和测试集。数据集的几种不同场景样本如图 6 所示。



图 6 数据集标注与检测结果对比图

Fig. 6 Comparison of data set annotation and detection results

3.2 评价指标

目标检测任务中通常会使用平均精度均值 (Mean Average Precision,  $mAP$ ) 来衡量模型的性能,通过计算每一个类别的平均精度 ( $AP$ ),再对所有类别的  $AP$  求平均得到。另外,2 个常用的评价指标是召回率 ( $Recall$ ) 和精确率 ( $Precision$ )。召回率表示被正确预测为正样本的比例,用于衡量模型对所有目标的检测覆盖率;而精确率则表示预测为正样本中真正为正样本的比例,用来评价模型预测结果的准确性。本文采用  $mAP$  和  $Recall$  来作为评价迷彩伪装目标检测的主要指标。计算公式分别如下:

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \tag{16}$$

$$Recall = \frac{TP}{TP + FN} \tag{17}$$

$$Precision = \frac{TP}{TP + FP} \tag{18}$$

检测结果分为 4 种不同情况,分别是真阳性 (True Positive,  $TP$ )、假阳性 (False Positive,  $FP$ )、真阴性 (True Negative,  $TN$ )、假阴性 (False Negative,  $FN$ ),这里  $T$  表示 True;  $F$  表示 False;  $P$  表

示 Positive;  $N$  表示 Negative。详细定义见表 1。

表 1 评价指标

Table 1 Evaluation indicators

| 评价指标                        | 含义               |
|-----------------------------|------------------|
| 真阳性 (True Positive, $TP$ )  | 正确,预测为正样本且确实是正样本 |
| 假阳性 (False Positive, $FP$ ) | 误检,预测为正样本但并非是正样本 |
| 真阴性 (True Negative, $TN$ )  | 正确,预测为负样本且确实是负样本 |
| 假阴性 (False Negative, $FN$ ) | 漏检,预测为负样本但并非是负样本 |

3.3 实验环境与参数配置

模型训练过程中,设置了 300 个  $Epochs$  的训练轮数,  $Batch\_size$  为 32,图片尺寸大小为  $640 \times 640$ ,选取 SGD 优化器,初始学习率固定为 0.01,动量为 0.937。对数据集进行预测时,设置  $Batch\_size$  为 1,以检测出模型的实时  $FPS$  值。

对比算法包括 YOLOv5s、YOLOv7、YOLOv8n、SSD、Faster-RCNN、所有算法选择开源代码进行手动复现,对比代码均使用默认参数,操作平台为 Pytorch1.10,Python 版本为 3.8.10,训练平台为 NVIDIA 3080Ti 显卡。模型训练过程中,设置了 300 个  $Epochs$  的训练轮数,  $Batch\_size$  为 32,图片尺寸大小为  $640 \times 640$ ,选取 SGD 优化器,初始学习率



固定为 0.01, 动量为 0.937。对数据集进行预测时, 设置 *Batch\_size* 为 1, 以检测出模型的实时 *FPS* 值。

对比算法包括 YOLOv5s、YOLOv7、YOLOv8n、SSD、Faster-RCNN, 所有算法选择开源代码进行手动复现, 对比代码均使用默认参数, 操作平台为 Pytorch1.10, Python 版本为 3.8.10, 训练平台为 NVIDIA 3080Ti 显卡。

### 3.4 实验结果与分析

经过改进, YOLO-FCL 算法与多种目标检测算法对比结果见表 2, 检测效果见图 6。

表 2 多种经典算法对比

| Table 2 Comparison of multiple classical algorithms |            |              |               |               |
|-----------------------------------------------------|------------|--------------|---------------|---------------|
| 算法                                                  | 主干网络       | <i>mAP</i>   | <i>Recall</i> | <i>Params</i> |
| Faster-RCNN                                         | ResNet50   | 0.901        | 0.906         | 2 350 000     |
| SSD                                                 | VGG        | 0.853        | 0.672         | 13 800 000    |
| YOLOv5s                                             | CSPDarkNet | 0.933        | 0.887         | 7 033 114     |
| YOLOv7                                              | E-ELAN-Net | 0.904        | 0.814         | 37 196 556    |
| YOLOv8n                                             | CSPDarkNet | 0.946        | 0.899         | 3 157 200     |
| YOLO-FCL                                            | CSPDarkNet | <b>0.956</b> | <b>0.915</b>  | 2 424 313     |

由表 2 和图 6 可以看出, YOLOv8-FCL 对于伪装人员的检测方面有着较好的效果, 在保证快速、实时检测的情况下, 仍能提高检测精度以及召回率。相比于 YOLOv8n 算法, 在参数量降低了 23% 的情况下, *mAP* 和 *Recall* 指标上仍表现优秀, 分别提升了 1% 和 1.6%。对比其他 4 种经典算法, 本文各项指标也均表现出明显的优势。证明了 YOLOv8-FCL 算法能够更加出色地解决迷彩伪装目标检测任务。

为了进一步验证改进模型相较于原始模型的优势性, 进一步开展消融实验, 分步添加改进的模块, 以展现改进的作用。消融实验结果见表 3。

表 3 消融实验结果

| Table 3 Results of ablation experiments |            |     |              |               |                   |            |
|-----------------------------------------|------------|-----|--------------|---------------|-------------------|------------|
| YOLOv8n                                 | Faster_C2f | LSK | <i>mAP</i>   | <i>Recall</i> | <i>Parameters</i> | <i>FPS</i> |
| ✓                                       |            |     | 0.946        | 0.899         | 3 157 200         | 98         |
| ✓                                       | ✓          |     | 0.944        | 0.905         | 2 452 000         | 116        |
| ✓                                       |            | ✓   | 0.950        | 0.903         | 3 275 670         | 100        |
| ✓                                       | ✓          | ✓   | <b>0.956</b> | <b>0.915</b>  | <b>2 424 313</b>  | <b>110</b> |

由表 3 可以看出, 单独引入 Faster\_C2f 模块, 较基准模型, *mAP* 降低了 0.2%, *Recall* 提升了 0.6%, 参数量减少 22%; 仅增加 LSK 注意力模块, *mAP* 和 *Recall* 皆提升了 0.4%。当两者同时改进时, 在减少 22% 的参数量下, 大大提升了检测的效果, *mAP* 和

*Recall* 分别提升了 1.0% 和 1.6%, 相比于原始算法得到了显著的提升, 有效提高了对迷彩伪装目标的检测能力。此外, 整个模型的实时帧率 (Frames Per Second, *FPS*) 可达到 110, 表明改进后的模型在保持较高检测精度的同时, 具备优异的实时性能。

## 4 结束语

为了快速、精准定位伪装目标, 在确保实时检测速度的同时提升检测效果, 提出了 YOLOv8-FCL 算法。通过改进 C2f 模块结构, 融合 PConv 轻量化卷积块设计出 FC2f 模块, 在保持 C2f 特征提取能力的情况下, 大幅度减少了参数, 从而实现了模型的轻量化。为了突出迷彩伪装目标的位置, 经过一系列实验, 选择在 SPPF 模块前加入 LSK 注意力机制, 通过动态调整感受野大小来增强特征提取能力。

实验结果表明, YOLOv8-FCL 算法在减少了 23% 的参数的前提下, 仍能保持较高的检测精度。*mAP* 较基线模型提高了 1%, *Recall* 提高了 1.6%。鉴于技术的快速发展以及技术迭代更新的加速趋势, 未来工作将致力于继续研究和完善模型, 以便应对未来战争场景中更为复杂的伪装技术挑战。

## 参考文献

[1] 吴哲, 汪文馨, 宋智琳. 科技赋能战场伪装问题探析[J]. 军事文摘, 2024 (23): 64-66.

[2] 韩彤, 曹铁勇, 郑云飞, 等. 迷彩伪装目标检测的视觉特征偏好研究[J]. 计算机技术与发展, 2023, 33(12): 193-199.

[3] 曹文娜, 王志宇, 陆叶洪, 等. 涂料印花、涂层织物在军事伪装领域中的应用[J]. 针织工业, 2023 (10): 43-48.

[4] LENC K, VEDALDI A. R-CNN minus R[J]. arXiv preprint arXiv, 1506.06981, 2015.

[5] GIRSHICK R. Fast R-CNN[C]// Proceedings of the IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ: IEEE, 2015: 1440-1448.

[6] REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.

[7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only Look once: Unified, real-time object detection[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2016: 779-788.

[8] LIU Wei, DRAGOMIR A, DUMITRU E, et al. SSD: Single shot multibox detector[C]// Proceedings of European Conference on Computer Vision (ECCV). Cham: Springer, 2016: 21-37.

[9] LIN T Y, GOYAL P, GIRSHICK R Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.

[10] FAN Dengping, JI Geping, SUN Guolei, et al. Camouflaged object detection[C]// Proceedings of the IEEE/CVF Conference

on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2020: 2777–2787.

[11]王杨,曹铁勇,杨吉斌,等. 基于 YOLOv5 算法的迷彩伪装目标检测技术研究[J]. 计算机科学,2021,48(10):226–232.

[12]ZHANG Qing, YAN Weiqi. CFANet: A cross-layer feature aggregation network for camouflaged object detection [C]//Proceedings of 2023 IEEE International Conference on Multimedia and Expo (ICME). Piscataway, NJ:IEEE, 2023: 2441–2446.

[13]LYU Y X, ZHANG H, LI Y, et al. UEDG: Uncertainty-edge dual guided camouflage object detection[J]. IEEE Transactions on Multimedia, 2024,26:4050–4060.

[14]YANG Yang, ZHANG Qiang. Finding camouflaged objects along the camouflage mechanisms [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024,34(4): 2346–2360.

[15]LIN T Y, DOLLAR P, GIRSHICKR, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. (CVPR). Piscataway,NJ:IEEE, 2017:2117–2125.

[16]LIU Shu, QI Lu, QIN Haifang, et al. Path aggregation network for instance segmentation [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. (CVPR). Piscataway,NJ:IEEE,2018:8759–8768.

[17]CHEN Jierun, KAO S, HE Hao, et al. Run, don ´t walk: Chasing higher FLOPS for faster neural networks [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway,NJ:IEEE, 2023: 12021–12031.

[18]HU Jie, SHEN Li, ALBANIE S, et al. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2018: 7132–7141.

[19]WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). Cham:Springer,2018: 3–19.

[20]WANG Qilong, WU Banggu, ZHU Pengfei, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2020: 11534–11542.

[21]LI Yuxuan, HOU Qibin, ZHENG Zhaohui, et al. Large selective kernel network for remote sensing object detection [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway,NJ:IEEE, 2023: 16794–16805.

[22]梁新宇,林浩坤,杨辉,等. 迷彩伪装目标图像语义分割数据集的构建[J]. 激光与光电子学进展, 2021, 58 (4): 214–220.