

文章编号: 1674-5566(2023)05-1080-10

DOI: 10.12024/jsou.20230604241

## 融合通道剪枝与 ByteTrack 的轻量化金枪鱼渔获数量实时检测

刘雨青<sup>1</sup>, 李杰<sup>1</sup>, 宋利明<sup>2,3</sup>, 魏星<sup>1</sup>, 陈明<sup>1</sup>, 隋恒寿<sup>4</sup>, 李彬<sup>4</sup>,  
李同<sup>4</sup>

(1. 上海海洋大学 工程学院, 上海 201306; 2. 上海海洋大学 海洋科学学院, 上海 201306; 3. 上海海洋大学 国家远洋渔业技术研究中心, 上海 201306; 4. 中水集团远洋股份有限公司, 北京 100032)

**摘要:** 自动准确收集渔业捕捞数据是电子观察员系统的重要组成部分, 然而, 由于工作环境的复杂性和跟踪的不稳定性, 金枪鱼延绳钓渔获数量自动估计在实践部署中仍存在挑战。本研究设计了一个轻量级计数网络对渔船上的实时视频数据进行自动处理, 实现对金枪鱼渔获物的实时跟踪和计数。本研究选择 YOLOv5s 作为基准网络, 首先采用通道剪枝算法对 YOLOv5s 的主干网络进行修剪, 结果表明, 剪枝后的模型检测精度  $mAP_{0.5-0.95}$  达到 68.8%, CPU 下检测速度为 16.5 帧/s(FPS), 与原始模型相比, 检测效果基本不变, 模型的参数量、模型大小和计算量分别减少了 67.2%、66.4% 和 42.5%, 检测速度提高了 33.1%。其次, 利用 ByteTrack 算法实现了多目标的实时跟踪, 优化了计数区域形状, 解决了被跟踪金枪鱼身份(ID)跳变导致的计数偏差问题, 10 个视频的测试结果表明, 该方法的平均计数准确率为 80%, 视频处理速度为 50.7 帧/s, 满足工业级实时检测要求。综上, 该模型具有轻量化、高精度、实时性等优点, 可在复杂的工作环境下完成对延绳钓捕捞结果的实时监控, 为实现渔业自动化提供思路。

**关键词:** 金枪鱼数量; 通道剪枝; ByteTrack; 实时检测; YOLOv5; 多目标追踪

**中图分类号:** TP 391.4 **文献标志码:** A

准确统计捕捞数据有助于渔业管理者全面了解捕捞活动情况, 制定科学的管理措施, 实现渔业的可持续发展和海洋生态保护<sup>[1-3]</sup>。人类观察员很难在持续、高强度的工作中保持统计数据的准确性<sup>[4]</sup>, 同时, 金枪鱼延绳钓渔船在海上连续作业时间普遍超过一年, 经常延迟提交渔捞日志, 且部分企业还存在填写不准确或者遗漏的情况, 渔捞日志的准确性和时效性存在不足<sup>[5]</sup>。因此, 为了提高捕捞数据的准确性并减少人工观察员的工作量, 需要采用一种自动化的方法对捕捞作业进行实时、准确地监测处理, 并能够记录捕捞的鱼类数据。

针对鱼类图像识别问题, 研究者提出了基于卷积神经网络(Convolutional neural network, CNN)的方法, 在鱼类识别、海洋捕捞等方面得到

应用<sup>[6-8]</sup>。涂雪滢等<sup>[9]</sup>提出基于 ResNet 的鱼类识别模型, 增加了对不同姿态鱼类图像的训练, 提高了模型的泛化能力; 张俊龙等<sup>[10]</sup>基于 CNN 构建深度学习模型, 将鱼类特征进行权重化, 提高了对海洋鱼类识别的准确率。然而, 这些方法一般用于检测单幅图像中鱼的种类, 由于其模型复杂, 限制了在现实场景中的应用, 而模型轻量化方法可以有效解决这个问题<sup>[11]</sup>。CAI 等<sup>[12]</sup>提出用轻量级 ModelNetV1 替换 YOLOv3 的主干网络实现对鱼类的快速检测; 朱明等<sup>[13]</sup>采用优化后的 ModelNetV3 网络对鱼群摄食图像特征筛选, 实现了对鲈鱼摄食状态进行评估; IQBAL 等<sup>[14]</sup>在鱼类识别问题中, 通过改变 AlexNet 网络中的卷积层结构和全连接层数量, 解决了原网络训练过程中占用内存大, 计算复杂的问题。这些研究证明了

收稿日期: 2023-06-15 修回日期: 2023-08-07

基金项目: 国家自然科学基金(32273185); 中水集团远洋股份有限公司技术研发项目(D-8006-20-0180)

作者简介: 刘雨青(1976—), 女, 博士, 副教授, 研究方向为自动控制技术和基于深度学习的图像识别技术。E-mail: yqliu@shou.edu.cn

通信作者: 宋利明, E-mail: lmsong@shou.edu.cn

版权所有 ©《上海海洋大学学报》编辑部(CC BY-NC-ND 4.0)

Copyright © Editorial Office of Journal of Shanghai Ocean University (CC BY-NC-ND 4.0)

<http://www.shhydx.com>

轻量化后的 CNN 在鱼类识别方面的网络表现能力。

在鱼类识别研究的基础上,一些学者进一步开展了针对鱼类的目标追踪和计数的研究,为鱼类数据的自动化处理提供了方法<sup>[15]</sup>。TSENG 等<sup>[16]</sup>将视频图像进行分帧处理后利用 Mask R-CNN 实现鱼类的识别,并提出新型鱼类计数网络;吴必朗等<sup>[17]</sup>通过对比选择 YOLOv5s 作为识别的主要算法,使用 DeepSORT 算法进行目标计数;ZHANG 等<sup>[18]</sup>采用多列卷积神经网络作为前端以及扩张卷积神经网络作为后端的方式,建立了一种混合神经网络实现鱼类种群自动计数。

上述方法存在 2 个问题:(1)模型较大,耗费大量计算资源,难以满足实时性及模型部署等要求<sup>[19-20]</sup>;(2)遮挡和不规则运动容易导致跟踪丢失。为了解决以上问题,本研究采用通道剪枝算法<sup>[21]</sup>进行轻量化处理,解决 YOLOv5 模型冗余通道较多、检测速度低等缺点,在计数任务中,使用 ByteTrack 多目标追踪算法跟踪每帧画面中的金枪鱼,并设计了一种特定的跟踪区域计数方法,对追踪到的金枪鱼进行统计,为实现渔业自动化提供思路。

## 1 材料与方法

### 1.1 材料

#### 1.1.1 实验数据

所用的影像视频数据集为中水集团远洋股份有限公司的金枪鱼延绳钓渔船在南太平洋作业数据,分辨率为 1 920 像素×2 560 像素。通过对视频监控系统采集的视频进行筛选,选取了 40 个视频数据作为实验样本,涵盖了不同的天气和光照条件,每个视频的时长约为 10 min。为避免数据泄露而导致训练结果过拟合的问题,对其中的 30 个视频数据按照 8:1:1 分为训练集、验证集、测试集,剩余的 10 个视频用于测试目标追踪的效果。将视频每隔 30 帧截取 1 次,并剔除相似度高和不包含金枪鱼的图像,最终从 30 个视频中获取 1 070 张图片构成实验所需数据集,采用 LabelImg 软件对图片进行标注后生成 txt 文件,包含了前景的类别和对应的位置坐标。

#### 1.1.2 实验平台

所有实验均在 Win 10 操作系统下进行,CPU 型号为 Intel(R) Core(TM) i5-12490F(3.00 GHz)、

GPU 型号为 NVIDIA RTX 2080Ti,开发环境为 Python 3.8,PyTorch 版本为 1.9.0。

### 1.2 金枪鱼检测与统计方法

#### 1.2.1 总体技术路线

对金枪鱼捕捞过程图片进行标注后将其输入 YOLOv5s 网络模型中进行训练,实现对金枪鱼的准确检测;利用通道剪枝算法对模型中存在的冗余通道和权重参数进行剪裁,在保证检测精度的情况下对模型结构、参数数量进行压缩;优化后的 YOLOv5s 的检测结果传输至 ByteTrack 追踪网络,在多帧图像中对金枪鱼目标进行连续追踪,并为每个目标分配唯一身份(ID),同时设计特定的跟踪计数区域,对区域内的金枪鱼进行计数,结合检测与追踪实现了金枪鱼的计数。

#### 1.2.2 基于 YOLOv5s 的金枪鱼检测网络

为了获得一种实时、准确、可靠且易于实现的金枪鱼检测算法,本研究使用 YOLOv5s 算法<sup>[22-24]</sup>,该算法由主干网络(Backbone)、多尺度特征融合网络(Neck)和 3 个检测头(Detection head)组成(图 1)。使用 CSPDarkNet<sup>[25]</sup>作为主干网络,负责提取不同尺度的图像特征,多尺度特征融合网络连接至主干网络,负责融合不同尺度的特征,产生 3 种不同比例的特征图,尺度从大到小,分别用于检测小型、中型和大型物体。每个检测头的输出是一组检测框,利用非极大值抑制(Non maximum suppression, NMS)方法从单个对象生成的多个预测框中选择最佳边界框。

#### 1.2.3 基于 YOLOv5s 通道剪枝算法的金枪鱼检测

常规的 YOLOv5s 在实验室 CPU 条件下的检测速度只能达到 12.4 帧/s,不能满足实时检测的要求,为了提高检测效率,本研究采用通道剪枝方法对网络结构进行简化,降低模型复杂度。

通道剪枝算法流程图如图 2 所示,将比例因子  $\gamma$  引入到批量归一化(Batch normalization, BN)层, $\gamma$  与对应通道的输出相乘,对  $\gamma$  施加正则化并在训练网络的同时联合训练  $\gamma$ ,从而使参数稀疏<sup>[26]</sup>。稀疏化训练过程中使用的损失函数如公式(1)所示。

$$L = \sum_{(x,y)} [f(x, W), y] + \lambda \sum_{\gamma \in \Gamma} g(\gamma) \quad (1)$$

该损失函数  $L$  由两部分组成,等式的第一项

是正常训练条件下的损失函数,其中  $x$  为输入,  $W$  为网络的权重参数,  $y$  为真值。第二项为稀疏化训练权重因子  $\gamma$  的损失函数;  $\lambda$  是稀疏化训练系数。

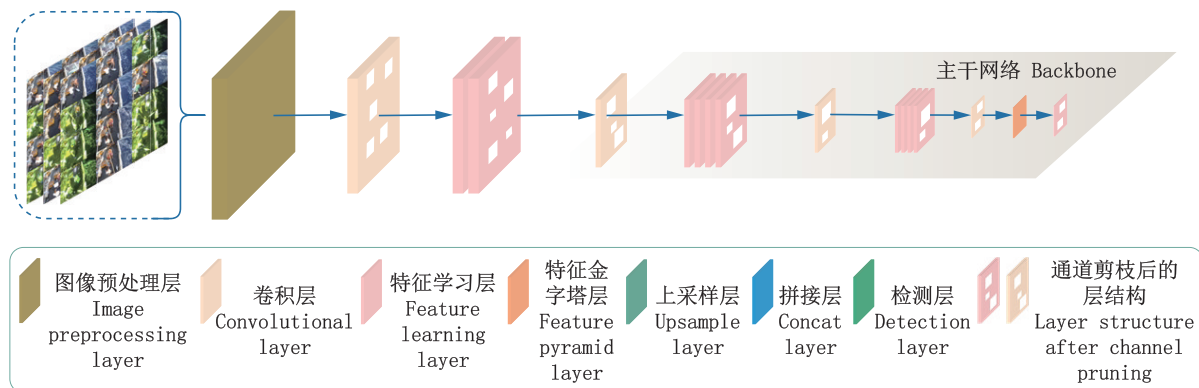
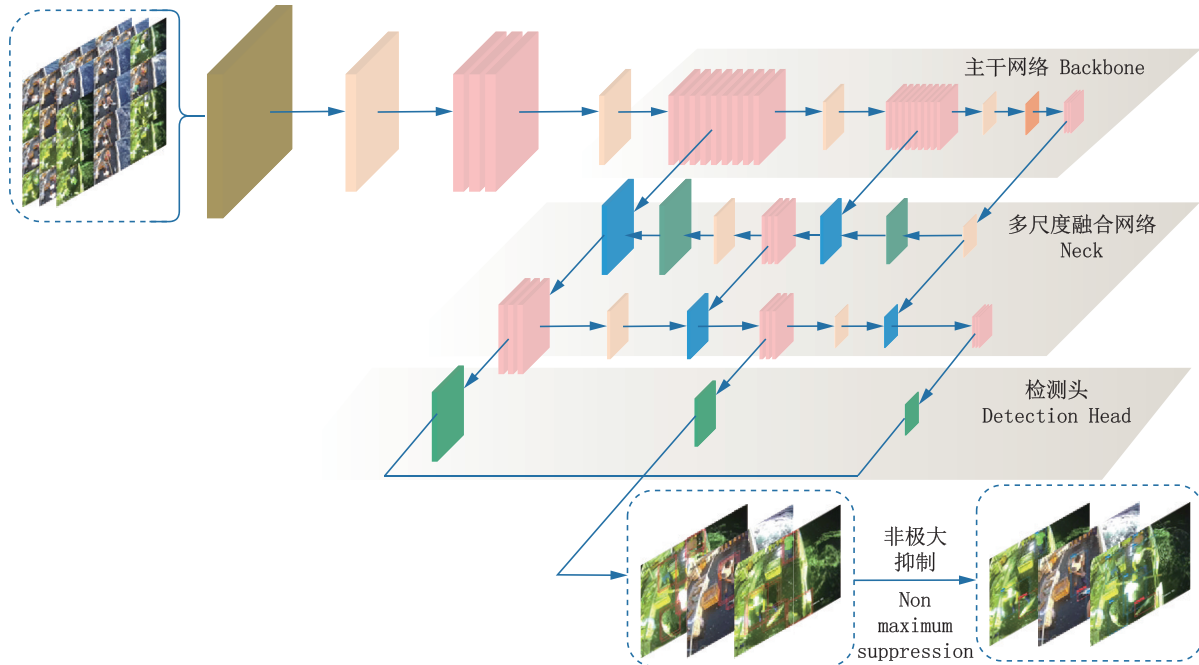


图1 网络结构图

Fig. 1 The network structure




图2 通道剪枝流程图

Fig. 2 Flow chart of channel pruning

稀疏化后, 权衡检测速度和精度, 本研究将剪枝率设置为0.65。如图3所示, 模型剪枝前后通道数的变化非常显著, 大部分卷积层的通道数

大幅减少, 整个模型的通道数从原来的9 504个减少到了3 578个, 从而减少了模型的复杂度。采用预训练金枪鱼YOLOv5s模型的权重参数对

修剪后的模型进行微调,这一步骤可以在一定程度上弥补剪枝后精度的下降。

### 1.2.4 基于ByteTrack算法的金枪鱼多目标追踪

为兼顾金枪鱼实时检测性能和追踪的效果,本文采用ByteTrack多目标追踪算法<sup>[27]</sup>,对剪枝后的YOLOv5s检测到的金枪鱼目标进行跟踪与统计。ByteTrack多目标追踪方法使用卡尔曼滤波<sup>[28]</sup>预测下一帧中当前帧的轨迹,然后将预测框和检测框的交并比(Intersection over union, IoU)

作为两次匹配的相似度,通过匈牙利算法<sup>[29]</sup>完成匹配。ByteTrack多目标跟踪方法的具体工作流程如图4所示。首先,根据检测结果,将所有检测框分成高分检测框( $D_{high}$ )和低分检测框( $D_{low}$ ),首次使用高分检测框匹配之前的跟踪轨迹,在第二次追踪过程中,低分框与未匹配的跟踪轨迹( $T_{remain}$ )进行匹配,将两次不匹配的跟踪轨迹保留30帧。最后,为不匹配任何现有轨迹的高分检测框( $D_{remain}$ )创建新的跟踪轨迹。

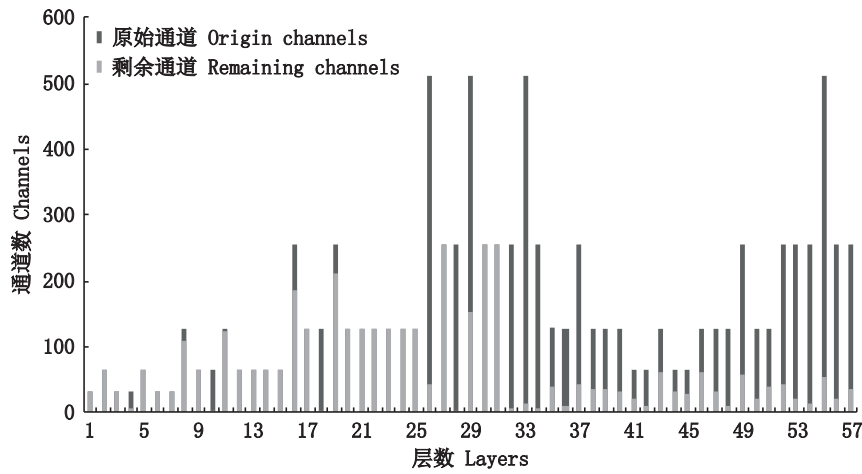


图3 剪枝前后通道数量对比

Fig. 3 Comparison of the number of channels before and after pruning

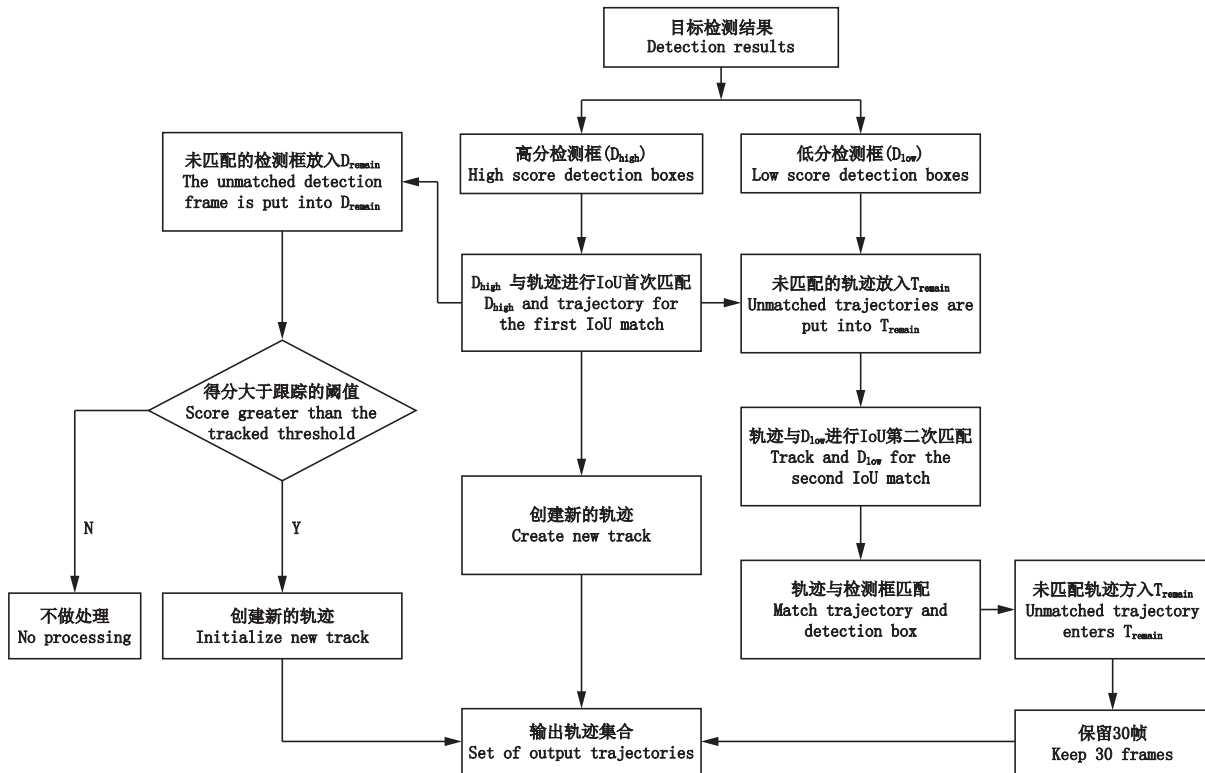


图4 ByteTrack跟踪算法流程图

Fig. 4 Flowchart of ByteTrack tracking algorithm



### 1.2.5 特定区域跟踪计数法

在使用 ByteTrack 进行金枪鱼跟踪时,仍然存在金枪鱼ID发生变化的情况,特别是在金枪鱼被捕捞上船的过程中。在跟踪计数过程中ID切换会导致预估的数量偏多,因此,ByteTrack算法生成的所有金枪鱼ID不直接作为金枪鱼总数的统计值。

为解决上述重复计数的问题,设计一种特定的跟踪区域计数方法。如图5所示,在运行金枪鱼跟踪计数算法时,使用一个由 $(x_a, y_a)$ 和 $(x_b, y_b)$ 组成的视觉框来表示特定的跟踪计数区域。该计数策略处理流程如图6所示,通过引入特定的跟踪计数区域,并根据金枪鱼在该区域内首次出现进行计数更新,可以有效减少重复计数问题。

针对设计的特定区域追踪计数方法,采用 $P_c$ (计数精度)评估视频中金枪鱼计数的性能,如公式2所示。

$$P_c = \left(1 - \frac{|N_g - N_a|}{N_g}\right) \times 100\% \quad (2)$$

式中: $N_g$ 为视频中的真实值,是通过手动计数获得的; $N_a$ 为算法给出的建议计数值。




图5 金枪鱼的跟踪计数区域

Fig. 5 Trace count areas for tuna

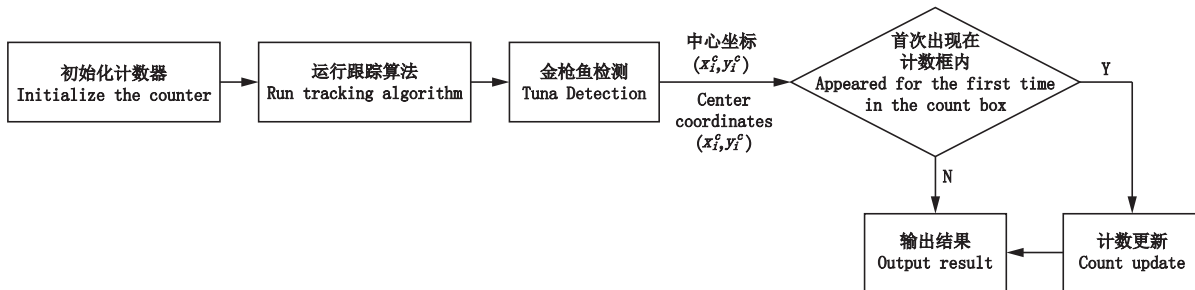


图6 金枪鱼计数流程图

Fig. 6 Tuna counting statistics flow chart

## 2 结果

### 2.1 评价指标

本研究使用了均值平均精度(Mean average precision, mAP)、准确率(Precision,  $P$ )、召回率(Recall,  $R$ )、参数量(Params)、浮点计算量(Floating point operations, FLOPs)和检测速度(帧/S, FPS)作为本次对比实验的主要评价指标,用于评估模型的性能。其中 $P$ 、 $R$ 和mAP的计算公式如下:

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (3)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (4)$$

式中: $T_p$ 为正确预测正样本的个数; $F_p$ 为错误预测负样本为正样本的个数; $F_N$ 为将正样本预测为

负样本的个数。

与准确率和召回率相比,平均精度可以更均衡地反映模型的全局检测性能。mAP是AP在各类别( $c$ )上的平均值,AP定义为精确召回曲线下的面积,mAP<sub>0.5</sub>表示IoU阈值为0.5时的平均精度值;mAP<sub>0.5-0.95</sub>表示IoU阈值以0.05为步长在0.5与0.95间取10个mAP的平均值。

$$mAP = \frac{1}{c} \sum_{i=1}^c AP_i \times 100\% \quad (5)$$

$$mAP_{0.5-0.95} = \frac{1}{10} (mAP_{0.5} + mAP_{0.55} + \dots + mAP_{0.9} + mAP_{0.95}) \times 100\% \quad (6)$$

### 2.2 剪枝前后模型的性能对比

为了验证本研究中通道剪枝算法对金枪鱼检测模型性能的影响,在测试集上对比了YOLOv5s基线模型和剪枝后模型的性能,结果如

表1所示。根据模型的参数量、计算量(FLOPs)和模型大小来比较模型效率,FLOPs用于衡量模型计算的复杂性。从表1可以看出,剪枝后模型参数量减少了67.2%,FLOPs减少了42.5%,模型大小减少了66.4%,剪枝后的模型大小仅为4.8 MB,同时与原始模型相比,在CPU上的FPS提升了为33.1%。尽管剪枝后模型的mAP有所下降,但微

调方法能够使模型精度恢复得更快,mAP<sub>0.5-0.95</sub>下降了10.9%。经过优化后,该算法在模型复杂性和硬件要求方面显著降低,同时性能下降在可接受范围之内。值得注意的是,优化后的算法可以实现CPU上进行实时目标检测,这提高了该算法在嵌入式移动终端等实际应用场景中使用的可能性。

表1 YOLOv5s金枪鱼检测模型剪枝前后性能对比

Tab. 1 Performance comparison of YOLOv5s tuna detection model before and after pruning

衡量指标 Metrics	原始 YOLOv5s Original YOLOv5s	剪枝后 After pruning	微调之后 After fine tuning
参数量 Parameters	7 025 023	2 301 148	2 301 148
计算量 FLOPs/G	16.0	9.2	9.2
模型大小 Volume/MB	14.3	9.1	4.8
mAP <sub>0.5-0.95</sub> /%	75.0	55.9	66.8
GPU下检测速度 FPS <sub>GPU</sub> /(帧/s)	114.0	118.6	147.4
CPU下检测速度 FPS <sub>CPU</sub> /(帧/s)	12.4	15.2	16.5

注:"mAP<sub>0.5-0.95</sub>"表示IoU阈值以0.05为步长在0.50与0.95间取10个mAP的平均值。

Notes: "mAP<sub>0.5-0.95</sub>" indicates that the average value of 10 mAP is selected between 0.50 and 0.95 for IoU threshold in steps of 0.05.

### 2.3 多目标追踪的结果

本研究融合通道剪枝算法与ByteTrack多目标追踪算法,实现对金枪鱼的追踪与计数。以剪枝微调后的YOLOv5s作为检测器,识别视频中的金枪鱼并输出相应的边界框。结合ByteTrack算法对金枪鱼进行多目标跟踪,部分跟踪结果如图7所示,在跟踪过程中,金枪鱼从水面拖到甲板上,为检测到的金枪鱼分配一个ID。在后续帧中,如果ID没有切换,则跟踪被证明是有效的,直到它从视野中消失。



图7 视频V2金枪鱼多目标跟踪结果示例

Fig. 7 Example of video V2 tuna multi-target tracking results

### 2.4 金枪鱼的计数结果

为了验证金枪鱼计数方法的有效性,在真实

捕捞环境下采集了多个视频,并将所提出算法得出的计数值与真实值进行比较,得出每次的准确率,结果如图8所示。计数准确率( $P_c$ )范围为50%至100%,总体平均 $P_c$ 为86%,特别是平均算法速度在45~60 FPS之间,满足实时在线检测要求。

## 3 分析与讨论

### 3.1 追踪误差对计数结果的影响

采用ByteTrack算法进行金枪鱼跟踪时,如果直接通过ID来统计金枪鱼的总数,可能会因ID切换而导致计数不准确。因此,本研究针对跟踪和计数任务分别进行处理,引入一种特定的跟踪区域计数方法,严格限制计数行为。经实验证明,这一方法是有效的。在实验过程中,仍然存在一些漏检情况,若中间计数区域未能检测到金枪鱼,将导致计数不足。另一个潜在问题是,金枪鱼进入计数区域后ID发生变化,可能导致重复计数。这些问题共同造成了14%的计数误差,是需要改进的方向。

### 3.2 计数区域大小和位置对计数结果的影响

在拉取金枪鱼的过程,工作人员会将金枪鱼从水门处拉上甲板,因此将计数区域位置设计在水门处,为了获得准确的计数结果,分析计数区域的位置和大小对计数结果的影响,如图9所示,

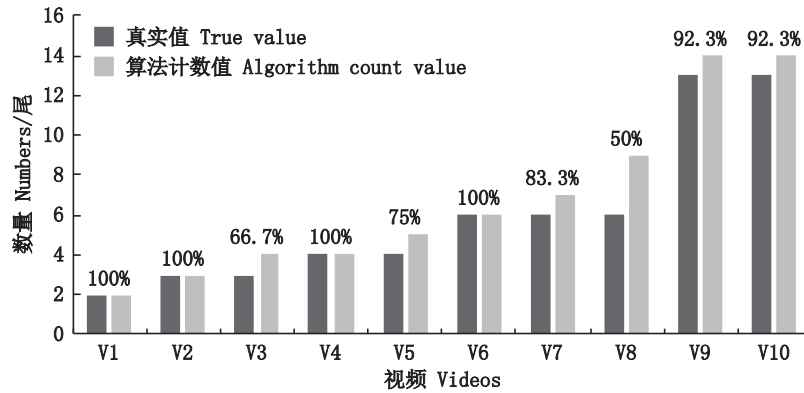


图8 真实值和算法计数值对比  
Fig. 8 Comparison of algorithmic counts and true value

在计数窗口的左侧区域设置了一个相同大小的区域(C区域)、在原计数区域设计了一个1.5倍的计数区域(B区域)。




图9 不同计数区域示意图  
Fig. 9 Schematic diagram of the different counting areas

$P_c$ 值为70.4%、B计数区域的 $P_c$ 值为55.9%。需要指出的是,在跟踪目标方面,在某些时间点可能没有出现跟踪丢失的情况,但随着时间的推移,由于遮挡等因素,目标可能无法被持续跟踪,从而导致计数无效。因此,计数区域的位置和大小对最终计数结果产生一定的影响。

#### 4 结论

本研究立足金枪鱼渔获量统计的准确性和视频数据处理的自动化,提出了一种融合通道剪枝和ByteTrack的特定区域计数方法。通过对比目前流行的目标检测算法,验证了剪枝后的YOLOv5s在满足实时性的同时维持较高的检测精度。其次,将剪枝微调后的网络作为ByteTrack多目标追踪网络的检测器,对视频数据中的金枪鱼进行实时跟踪,设计特定的跟踪区域计数方法,有效减少了重复计数。对比10个视频的测试结果,该方法的平均精度达到80%,集成算法运

5个测试视频上的结果如图10所示,A计数区域(本文采用)的 $P_c$ 值最高86%、C计数区域的

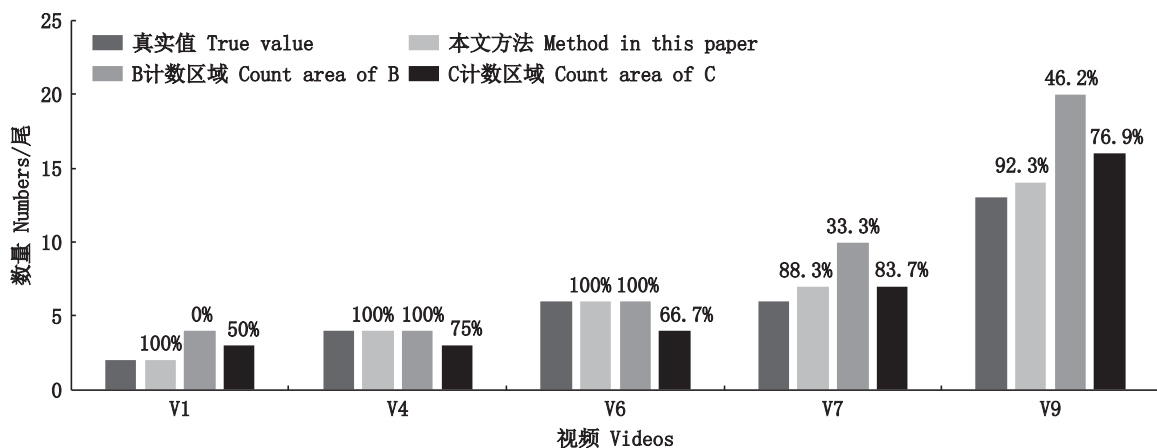


图10 不同计数区域结果对比  
Fig. 10 Comparison of the results of different counting areas

行速度超过 40 FPS,可以实现稳定、实时的渔获尾数估算。本研究验证了通过视频对金枪鱼实时计数的有效性,在后续研究中将通过布置多个摄像头解决遮挡问题和种类识别问题,提高每一种金枪鱼的计数准确率,并结合实例分割算法,构建出体质量预估系统,进一步提高各种金枪鱼渔获尾数和质量的估计精度。

#### 参考文献:

- [1] 王书献,张胜茂,朱文斌,等. 基于深度学习 YOLOV5 网络模型的金枪鱼延绳钓电子监控系统目标检测应用[J]. 大连海洋大学学报, 2021, 36(5): 842-850.  
WANG S X, ZHANG M S, ZHU W B, et al. Application of an electronic monitoring system for video target detection in tuna longline fishing based on YOLOV5 deep learning model[J]. Journal of Dalian Ocean University, 2021, 36(5): 842-850.
- [2] GOLDEN C D, ALLISON E H, CHEUNG W W L, et al. Nutrition: Fall in fish catch threatens human health [J]. Nature, 2016, 534(7607): 317-320.
- [3] YANG X T, ZHANG S, LIU J T, et al. Deep learning for smart fish farming: applications, opportunities and challenges [J]. Reviews in Aquaculture, 2021, 13(1): 66-90.
- [4] VAN HELMOND A T M, MORTENSEN L O, PLET-HANSEN K S, et al. Electronic monitoring in fisheries: lessons from global experiences and future opportunities [J]. Fish and Fisheries, 2020, 21(1): 162-189.
- [5] 邹莉瑾,戴小杰,许柳雄,等. 金枪鱼延绳钓渔捞日志管理现状与趋势[J]. 渔业信息与战略, 2015, 30(1): 35-39.  
ZOU L J, DAI X J, XU L X, et al. On the status of tuna longline fishery logbook [J]. Fishery Information & Strategy, 2015, 30(1): 35-39.
- [6] BICKNELL A W, GODLEY B J, SHEEHAN E V, et al. Camera technology for monitoring marine biodiversity and human impact [J]. Frontiers in Ecology and the Environment, 2016, 14(8): 424-432.
- [7] BROWN C J, DESBIENS A, CAMPBELL M D, et al. Electronic monitoring for improved accountability in western Pacific tuna longline fisheries [J]. Marine Policy, 2021, 132: 104664.
- [8] PROBST W N. How emerging data technologies can increase trust and transparency in fisheries [J]. ICES Journal of Marine Science, 2020, 77(4): 1286-1294.
- [9] 涂雪滢,刘世晶,钱程. 基于 ResNet 的典型养殖鱼类识别方法研究[J]. 渔业现代化, 2022, 49(3): 81-88.  
TU X Y, LIU S J, QIAN C. Study on the identification methods of typical cultured fish based on ResNet [J]. Fishery Modernization, 2022, 49(3): 81-88.
- [10] 张俊龙,曾国荪,覃如符. 基于深度学习的海底观测视频中鱼类的识别方法[J]. 计算机应用, 2019, 39(2): 376-381.  
ZHANG J L, ZENG G S, QIN R F. Fish recognition method for submarine observation video based on deep learning [J]. Journal of Computer Applications, 2019, 39(2): 376-381.
- [11] LIU Y Q, CHU H Y, SONG L M, et al. An improved tuna-YOLO model based on YOLOv3 for real-time tuna detection considering lightweight deployment [J]. Journal of Marine Science and Engineering, 2023, 11(3): 542.
- [12] CAI K W, MIAO X Y, WANG W, et al. A modified YOLOv3 model for fish detection based on MobileNetV1 as backbone [J]. Aquacultural Engineering, 2020, 91: 102117.
- [13] 朱明,张镇府,黄凰,等. 基于轻量级神经网络 MobileNetV3-Small 的鲈鱼摄食状态分类[J]. 农业工程学报, 2021, 37(19): 165-172.  
ZHU M, ZHANG Z F, HUANG H, et al. Classification of perch ingesting condition using lightweight neural network MobileNetV3-Small [J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(19): 165-172.
- [14] IQBAL M A, WANG Z J, ALI Z A, et al. Automatic fish species classification using deep convolutional neural networks [J]. Wireless Personal Communications, 2021, 116(2): 1043-1053.
- [15] BRADLEY D, MERRIFIELD M, MILLER K M, et al. Opportunities to improve fisheries management through innovative technology and advanced data systems [J]. Fish and Fisheries, 2019, 20(3): 564-583.
- [16] TSENG C H, KUO Y F. Detecting and counting harvested fish and identifying fish types in electronic monitoring system videos using deep convolutional neural networks [J]. ICES Journal of Marine Science, 2020, 77(4): 1367-1378.
- [17] 吴必朗,柳春娜,姜付仁. 基于 DeepSORT 算法的鱼道过鱼种类识别和计数研究[J]. 水利水电技术, 2022, 53(9): 152-162.  
WU B L, LIU C N, JIANG F R. Species identification and counting of fishes in fishway based on DeepSORT algorithm [J]. Water Resources and Hydropower Engineering, 2022, 53(9): 152-162.
- [18] ZHANG S, YANG X T, WANG Y Z, et al. Automatic fish population counting by machine vision and a hybrid deep neural network model [J]. Animals, 2020, 10(2): 364.
- [19] 张胜茂,孙永文,樊伟,等. 面向海洋渔业捕捞生产的深度学习应用研究进展[J]. 大连海洋大学学报, 2022, 37(4): 683-695.  
ZHANG S M, SUN Y W, FAN W, et al. Research



- progress in the application of deep learning methods for marine fishery production: a review[J]. *Journal of Dalian Ocean University*, 2022, 37(4): 683-695.
- [20] MICHELIN M, ELLIOTT M, BUCHER M, et al. Catalyzing the growth of electronic monitoring in fisheries [R]. California Environmental Associates, 2018.
- [21] WANG D D, HE D J. Channel pruned YOLO V5s-based deep learning approach for rapid and accurate apple fruitlet detection before fruit thinning [J]. *Biosystems Engineering*, 2021, 210: 271-281.
- [22] 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 review of YOLO object detection based on deep learning[J]. *Journal of Electronics & Information Technology*, 2022, 44(10): 3697-3708.
- [23] JIANG P Y, ERGU D, LIU F Y, et al. A review of Yolo algorithm developments [J]. *Procedia Computer Science*, 2022, 199: 1066-1073.
- [24] 刘芳, 刘玉坤, 林森, 等. 基于改进型YOLO的复杂环境下番茄果实快速识别方法[J]. *农业机械学报*, 2020, 51(6): 229-237.
- LIU F, LIU Y K, LIN S, et al. Fast recognition method for tomatoes under complex environments based on improved YOLO [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(6): 229-237.
- [25] MAHASIN M, DEWI I A. Comparison of CSPDarkNet53, CSPResNeXt-50, and EfficientNet-B0 Backbones on YOLO V4 as Object Detector[J]. *International Journal of Engineering, Science and Information Technology*, 2022, 2(3): 64-72.
- [26] 雷杰, 高鑫, 宋杰, 等. 深度网络模型压缩综述[J]. *软件学报*, 2018, 29(2): 251-266.
- LEI J, GAO X, SONG J, et al. Survey of deep neural network model compression [J]. *Journal of Software*, 2018, 29(2): 251-266.
- [27] ZHANG Y F, SUN P Z, JIANG Y, et al. ByteTrack: Multi-object tracking by associating every detection box [C]//17th European Conference on Computer Vision. Tel Aviv, Israel: Springer, 2022: 1-21.
- [28] WELCH G, BISHOP G. An introduction to the Kalman filter[M]. Chapel Hill, NC, United States: University of North Carolina, 1995.
- [29] KUHN H W. The Hungarian method for the assignment problem[J]. *Naval Research Logistics Quarterly*, 1955, 2(1/2): 83-97.

## Tuna catch real-time detection by fusing channel pruning with ByteTrack lightweight network

LIU Yuqing<sup>1</sup>, LI Jie<sup>1</sup>, SONG Liming<sup>2,3</sup>, WEI Xing<sup>1</sup>, CHEN Ming<sup>1</sup>, SUI Hengshou<sup>4</sup>, LI Bin<sup>4</sup>, LI Tong<sup>4</sup>

(1. College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China; 2. College of Marine Sciences, Shanghai Ocean University, Shanghai 201306, China; 3. National Engineering Research Center for Oceanic Fisheries, Shanghai 201306, China; 4. CNFC Overseas Fisheries Co., LTD., Beijing 100032, China)

**Abstract:** Automatic and accurate collection of fishery catch data is an important part of the electronic observer system. However, automated tuna longline catch estimation remains challenging to deploy in practice due to the complexity of the working environment and the instability of tracking. In this study, a lightweight counting network was designed to automate the processing of real-time video data from fishing vessels in order to enable real-time tracking and counting of tuna catches on board fishing vessels. YOLOv5s was selected as the benchmark network in this study. The channel pruning algorithm was first used to prune the backbone network of YOLOv5s, and the results showed that the detection accuracy of the pruned model  $mAP_{0.5-0.95}$  reached 68.8%, and the detection speed was 16.5 frames per second (FPS) under CPU, which was basically unchanged compared with the original model. The number of parameters, model size and computation of the model were reduced by 67.2%, 66.4% and 42.5% respectively, and the detection speed was increased by 33.1%. Secondly, the ByteTrack algorithm was used to achieve real-time tracking of multiple targets, optimize the shape of the counting area and solve the problem of counting deviation caused by the jump in the identity (ID) of the tuna being tracked. The test results of 10 videos showed that the average counting accuracy of the method was 80% and the video processing speed was 50.7 FPS, which meets the requirements of industrial-grade real-time detection. In summary, the model had the advantages of light weight, high accuracy and real-time, which could complete the real-time monitoring of longline catch in complex working environments and provide a solution to realizing fisheries automation.

**Key words:** tuna individuals; channel pruning; ByteTrack; real-time detection; YOLOv5; multi-target tracking