DOI: 10.13382/j.jemi.B2307003

长尾分布下的微藻显微图像轻量级目标检测*

汪鲁才 陈春江 邹伊雯 谢 婷
(湖南师范大学工程与设计学院 长沙 410081)

摘 要:微藻显微图像目标检测技术是生物学研究和环境监测等领域重要研究方向之一。电子显微镜采集到的微藻图像数据集存在长尾数据问题。传统的微藻检测方法需要大量人工操作,耗时长且结果容易受到操作人员技术经验的影响。结合解决长尾分布的方法,本文提出了一种基于延迟重采样和知识蒸馏相结合的目标检测算法(DDM-YOLO)。先对微藻显微图像进行数据增强,然后针对长尾分布数据,采用延迟重采样,并在二阶段采用反向采样,关注难以分类的少数类别样本,改善目标检测性能。设计了一种轻量级目标检测网络架构,通过知识蒸馏来减少模型复杂度和计算量。实验结果表明,DDM-YOLO 算法的 mAP@0.5/%为 77.1%,与 YOLOv5s 相比提高了 6.1%,模型参数量为 3.88 MiB,减少了 45.4%。所提出的方法在微藻显微图像数据上取得了显著的性能提升,同时在资源受限条件下实现了高效的目标检测,大大降低了检测人员的工作量。

关键词:目标检测;长尾分布;延迟重采样;知识蒸馏
中图分类号:TP391.4 **文献标识码**:A **国家标准学科分类代码**:520.2060

Lightweight target detection for micro-algae microscopic images under long-tailed distribution

Wang Lucai Chen Chunjiang Zou Yiwen Xie Ting
(College of Engineering and Design, Hunan Normal University, Changsha 410081, China)

Abstract: Microalgae microscopic image target detection technology is one of the important research directions in fields such as biology and environmental monitoring. The dataset of microalgae images captured by electron microscope exhibits a long-tail data issue. Traditional methods for microalgae detection are notoriously labor-intensive, time-consuming, and heavily influenced by operator expertise. In this context, combining methods to address the long-tail distribution, this paper proposes a target detection algorithm called DDM-YOLO, which combines delayed resampling and knowledge distillation. The approach involves data augmentation for microalgae microscopic images and utilizes delayed resampling for long-tail data. In the second stage, reverse resampling is applied to focus on the challenging minority class samples, thereby enhancing the performance of target detection. Additionally, a lightweight target detection network architecture is designed, and knowledge distillation is employed to reduce model complexity and computational requirements. Experimental outcomes reveal that the DDM-YOLO algorithm achieves an mAP@0.5/% of 77.1%, surpassing the YOLOv5s algorithm by a notable 6.1%. The model parameter size is 3.88 megabytes, a significant 45.4% decrease. This proposed method significantly enhances performance on microalgae microscopic image data and efficiently performs target detection under resource-constrained conditions, substantially reducing the workload of detection personnel.

Keywords: object detection; long-tail distribution; delayed re-sampling; knowledge distillation

0 引 言

藻类在水生环境中分布广泛,类似于普通植物,微藻也能进行光合作用,产生氧气和有机物质,为水中的生物提供物质和能量来源[1],是水体生态系统中的关键组成部分。在生态系统中,藻类群落作为生物食物链中的初级生产者,对于维持生态平衡和物质循环有重要的作

收稿日期:2023-10-26 Received Date:2023-10-26
*基金项目:国家自然科学基金(62101188)、国家自然科学基金(62261001)、湖南省自然科学基金(2023JJ40450)项目资助

用[2]。通过监测水体中藻类群落的种类和数量,可以了解水体生态群落的组成情况,这对于水质监测和预防水体污染具有重要意义[3]。

随着计算机技术的发展,出现了基于机器学习和深度学习的计算机视觉方法用于微藻检测[4],如结合支持向量机、人工神经网络[5]、卷积神经网络[6]等模型。王攀[7]将 CNN 神经网络用于微藻识别,成功实现了对 10 种淡水藻进行识别。然而,该模型训练集中的图像仅包含单个藻类,因此只具备藻类识别的功能,无法对一张图像中的多个藻类进行计数。崔雪森等[8]使用一种基于 AlexNet 模型的微藻种类识别方法,对 7 种藻类进行了训练和测试。王羽徵等[9]提出了基于 VGG 的改进模型,其在藻类识别方面的准确率超过了普通的 VGG 网络,能够高精准地识别金藻和小球藻。张志栋[10]基于 Faster R-CNN 网络开展了藻类识别模型的训练,成功实现对夜光藻和青岛大扁藻的检测,并通过计算藻类的面积推算藻浓度。王晓阳[11]利用 YOLOv3 网络训练藻类数据,能对一张图像中的多种微藻进行检测,微藻种类达到了 10 种。Qian 等[12]基于 Faster R-CNN 的藻类检测方法,对 27 种藻类的数据集进行检测,平均检测精度均值为 74.64%。吴志高等[13]提出了一种基于 YOLOv7 的微藻轻量级实时检测方法,能对 14 种微藻进行实时检测。

这些研究工作都在数据分布平衡的数据集上表现出良好性能。但是,在真实情况下,微藻数据存在长尾分布情况。数据集中的头部类别包含绝大多数样本,导致尾部类别数据出现频率较低,从而影响了检测性能。并且在实际应用中,需要在资源受限的条件下满足一定的实时性。目前,长尾分布下的微藻显微图像检测方法,存在着检测精度较低,模型参数量大,检测速度慢等问题,对于将以上三者平衡好的微藻检测方法,当前的研究还不多。为了高效、快速、便捷地检测微藻显微图像中的目标,并提高检测精度,本文进行了深入研究。

本文主要工作包括:

1)建立了一个新的微藻显微图像数据集,其中涵盖了 58 种微藻种类,共计 3 426 张图像,每张图像都标注了微藻的位置和类别。

2)采用延迟重采样方法来训练神经网络,对微藻显微图像进行数据增强,并设计一个反向采样器,在二阶段采用反向采样,着重关注难以分类的少数类别样本,以改善目标检测性能。

3)对提出方法进行轻量化改进,将 YOLOv5 的特征提取网络替换为 MobileNetV3 网络,并使用教师网络对其进行知识蒸馏,提供一种实时高效的微藻显微图像检测方法。

1　YOLOv5 算法

YOLOv5 的主要结构由 4 个部分组成:输入、主干网、颈部网络层和检测终端,如图 1 所示。输入端主要包括数据增强、K-Means 聚类生成锚框以及图像解码等操作。

Backbone 网络[14-15]为特征提取部分,空间金字塔池化(spatial pyramid pooling,SPP)[16]模块实现了深层语义信息与浅层语义信息的融合。在 YOLOv5 中,颈部网络层采用了基于 FPN[17]和 PANet 的特征融合网络[18],使用上采样和下采样将来自不同层次的特征图融合,以此得到拥有多尺度信息的特征图,有助于获得更好的检测效果。

YOLOv5 的输出部分,采用大、中、小 3 个不同尺度的特征图进行预测,利用 *CIoU* 获得边界框回归损失,减少回归误差,得到更精准的分类与回归结果。YOLOv5 的损失函数主要由定位损失 L_{box}、置信度损失 L_{obj} 以及分类损失 L_{cls} 构成,总损失 L_{total} 如式(1)所示:

$$L_{total} = \sum_{i}^{N} (\gamma_1 L_{box} + \gamma_2 L_{obj} + \gamma_3 L_{cls}) \tag{1}$$

其中,γ_1、γ_2、γ_3 分别为这 3 种损失的权重。*CIoU* 是一种用于目标检测中的损失函数,*CIoU* 考虑了目标与锚框之间的距离、尺度以及惩罚项,这让目标框的回归更加稳定。*CIoU* 作为预测边界框的损失,其计算公式如式(2)所示:

$$CIoU = IoU - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha v \tag{2}$$

$\rho^2(b, b^{gt})$ 是两框(预测框和真实框)中心点的欧氏距离的平方,c 是最小包围框的对角线距离。调节参数 α 和修正因子 v 的公式如式(3)、(4)所示:

$$\alpha = \frac{v}{1 - IoU + v} \tag{3}$$

$$v = \frac{4}{\pi^2}(\arctan\frac{w^{gt}}{h^{gt}} - \arctan\frac{w}{h})^2 \tag{4}$$

2　本文方法

2.1　延迟重采样改进

1)反向采样

目前对具有挑战性的长尾分布的目标检测取得了巨大进展,属于不同范式的各种方法,例如元学习[19]和度量学习[20]已经进行成功地探索。除了这些复杂的方法外,对训练程序的一些简单改进也很有效,例如调整数据分布或损失函数。还有一些在长尾目标检测中常用的、易于装备的、超参数不敏感的技巧,即重新加权[21]、重新采样[22]、混合训练[23]和两阶段训练。本策略采用

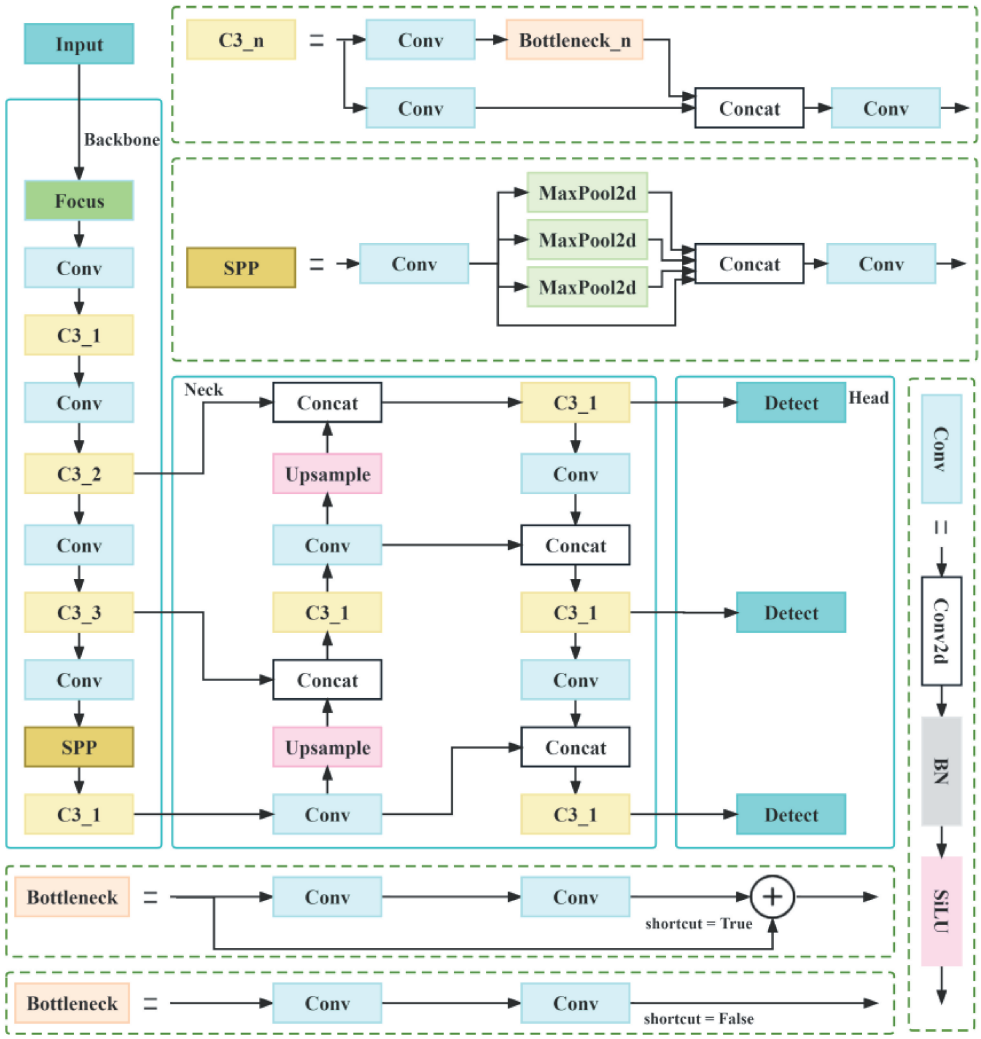

图 1 YOLOv5 网络结构

Fig. 1 Structure of YOLOv5 network

小角度旋转方式对小样本藻类进行数据增强,对训练集进行扩充后,设计了一个反向采样器,采用重新采样和两阶段训练相结合的方法,即延迟重采样方法,在不引入额外 FLOP 的情况下实现了优于现有方法的检测结果。

在第 1 阶段,数据的输入由普通采样器提供,该采样器以训练数据集中每个样本在整个训练期间只以原始数据概率进行采样。这个采样器保留了原始数据分布的特性,从而有利于学习表征。在第 2 阶段,目标在于减轻极端不平衡,特别是提高尾部类别的分类准确性。第 2 阶段的输入数据则来源于反向采样器。这意味着样本的选择更倾向于那些在第 1 阶段中分类效果较差的类别,从而平衡不同类别之间的样本分布,特别关注提升极端类别的分类性能。

对于反向采样器,反向采样器的原理是基于每个类别的样本量进行倒数比例的采样概率设置。这意味着,样本量越多的类别,其被采样的可能性就越小,将每张图片的所有类别的采样可能性加在一起,即为该张图片的被采概率。在式(5)中,表示类别 i 的样本数量为 N_i,所有类别的最大样本数量为 $N_{\max}$。

$$W_i = \frac{N_{\max}}{N_i} \tag{5}$$

根据式(6)得到每个类别 i 的采样可能性:

$$P_i = \frac{W_i}{\sum_{j=1}^{C} W_j} \tag{6}$$

每张图片的每个类别个数表示为 U_i,与整个数据集每个类别的采样可能性的乘积即为每张图片的对应每个类别的采样可能性,根据式(7),即每个类别的采样可能性之和为当前图片的采样可能性:

$$I_w = \sum U_i \times P_i \tag{7}$$

2)迁移学习

处理长尾问题时,采用迁移学习的方法首先学习原始数据的整体分布;接着,利用重采样策略对尾部类别进行学习。这种方法将充分学习了头部类别知识的网络,指导重采样下尾部类别网络的训练,在不降低整体精度的前提下提高尾部类别样本的分类精度。图 2 中所展示的训练过程是通过迁移学习,将第 1 阶段训练获得的最佳模型作为第 2 阶段的预训练模型。在第 2 阶段,使用反向采样的方法训练模型,最终利用第 2 阶段训练得到的最佳模型进行目标检测。这种方法可以有效处理长尾问题,提高尾部类别的分类性能,同时保持整体精度的稳定性。

具体而言,本文设计了两个阶段。两个阶段使用相同的训练网路,设 x 表示训练样本,y 是其对应的标签。对于两个阶段,分别对它们应用普通和反向采样器,并获得两个样本 (x_n, y_n) 和 (x_r, y_r) 作为输入数据,其中 (x_n, y_n) 用于第 1 阶段,(x_r, y_r) 用于第 2 阶段。

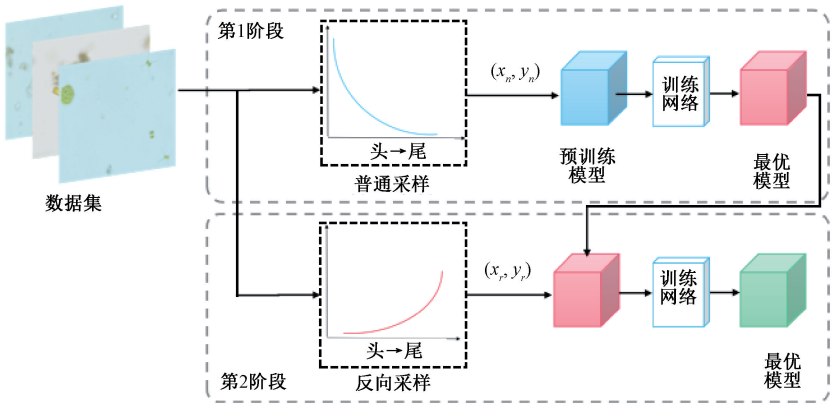

图 2　延迟重采样

Fig. 2　Delayed resampling

2.2　模型压缩

1)主干特征提取网络

为了模型在减少参数量的同时,能有较高的检测精度,本研究中将 YOLOv5 的 Backbone 网络替换为 MobileNetV3 网络。MobileNetV3[24]是基于深度可分离卷积和倒残差结构的网络,它削减了一些计算量比较多的网络层,并整合了通道注意力机制网络 SENet[25]。

深度可分离卷积是 MobileNet 系列的核心特征,利用深度卷积和逐点卷积对图像进行特征提取。若输入特征图的大小是 $D_F \times D_F \times M$,卷积核的大小是 $D_K \times D_K \times 1$,M 表示特征图通道数,N 表示卷积核数量,则常规卷积参数量 P_R 和计算量 Q_R 的计算公式分别为式(8)和(9):

$$P_R = D_K^2 MN \tag{8}$$

$$Q_R = D_K^2 D_F^2 MN \tag{9}$$

深度可分离卷积参数量 P_D 以及计算量 Q_D 的计算公式分别为式(10)和(11):

$$P_D = D_K^2 M + MN \tag{10}$$

$$Q_D = D_K^2 M \times (D_K^2 + N) \tag{11}$$

数量比值 R_P 以及计算量比值 R_Q 的公式分别为式(12)和(13):

$$R_P = \frac{P_D}{P_R} = \frac{1}{D_K^2} + \frac{1}{N} \tag{12}$$

$$R_Q = \frac{Q_D}{Q_R} = \frac{1}{D_K^2} + \frac{1}{N} \tag{13}$$

可以得知,深度可分离卷积参数量和计算量大约是常规卷积操作的 $\frac{1}{D_K^2} + \frac{1}{N}$ 倍。

2)基于特征的知识蒸馏

基于特征的知识蒸馏通过传递特征知识,学生模型能够更好地学习数据的抽象表示,从而在更少的参数和计算资源下获得更好的性能。教师模型在训练数据上学到的特征表示往往更具有泛化能力,通过将这些特征传递给学生模型,可以帮助学生模型更好地泛化到新的未见数据。本文选用改进后的 YOLOv5 作为教师网络,学生网络则为主干网络替换为 MobileNetV3 的 YOLOv5,同时对主干部分和颈部的特征进行知识蒸馏,如图 3 所示。采用一个跨层知识蒸馏的语义校准损失[26](semantic calibration for crosslayer knowledge distillement, SemCKDLoss)作为特征匹配损失。以通过将传递保持在匹配的语义级别来开发中间知识。将注意力机制应用于自动学习软层关联,该机制有效地将学生层与多个语义相关目标层绑定,而不是教师模型中的固定目标层(即一对多的知识转移)。为了对齐每个层对中的特征图的空间维度以计算总损失,学生层的特征图被投影到与相关目标层中的特征图相同的维度。通过利用语义校准和跨

多个层的特征图传输，可以在更适当的指导下有效地优化学生模型。蒸馏损失如式(14)所示。

$$L_S = \sum_{(s_l,t_l)\in C} \boldsymbol{\alpha}_{(s_l,t_l)} Dist(F_u^t, Proj(F_{s_l}^s, t_l)) \quad (14)$$

将训练的学生模型和教师模型在骨干网络和颈部网络的多个层上产生多个特征映射，其中，每个学生层的特征映射通过投影函数 $Trans^t(\cdot) = Proj(\cdot,\cdot)$ 进行变换，目标层的特征映射通过恒等变换 $Trans^t(\cdot) = I(\cdot)$ 保持不变。对于相应的实例，向量 $\boldsymbol{\alpha}_{(s_l,t_l)}$ 的第 i 个元素记为 $\alpha^i_{(s_l,t_l)}$。利用学习到的注意力分布，通过对候选师生层对特征映射之间的每个个体距离加权求和来计算总损失。

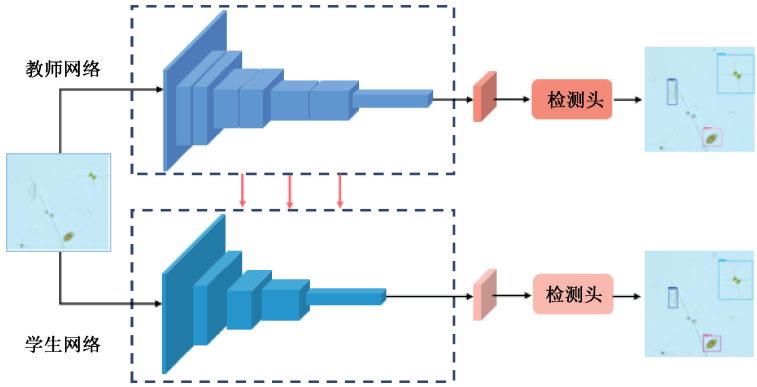

图 3 蒸馏总体框架

Fig. 3 Distillation overall framework

3 实验与结果分析

3.1 数据集

在数据集收集过程中，通过电子显微镜采集自湖南等地的地表水流域，然后通过人工整理筛选后得到。数据集包括平裂藻属、色球藻属、聚球藻属、微囊藻属 、席藻属、直链藻属等 58 种藻类，共 3 426 张图像。藻类标签数量的分布如图 4 所示，从左到右依次为微囊藻属、浮丝藻属、网球藻属、盘星藻属、针杆藻属等微藻呈降序排列，其中微囊藻属最多(5 439 个)，顶棘藻属，囊裸藻属等最少(1 个)。通过 Labelmg 进行种类、数量的标注，形成标准微藻显微图像数据库。在微藻显微图像数据集中，每张图像都标注了藻类的位置和类别信息。在训练模型之前，按照 9∶1 的比例对数据集进行随机划分为训练集和测试集。随后，在训练集上进行数据增强以丰富数据，通过对图像进行小角度旋转，扩充数据集至 6 852 张图像。并且进行了 mosaic 数据增强。

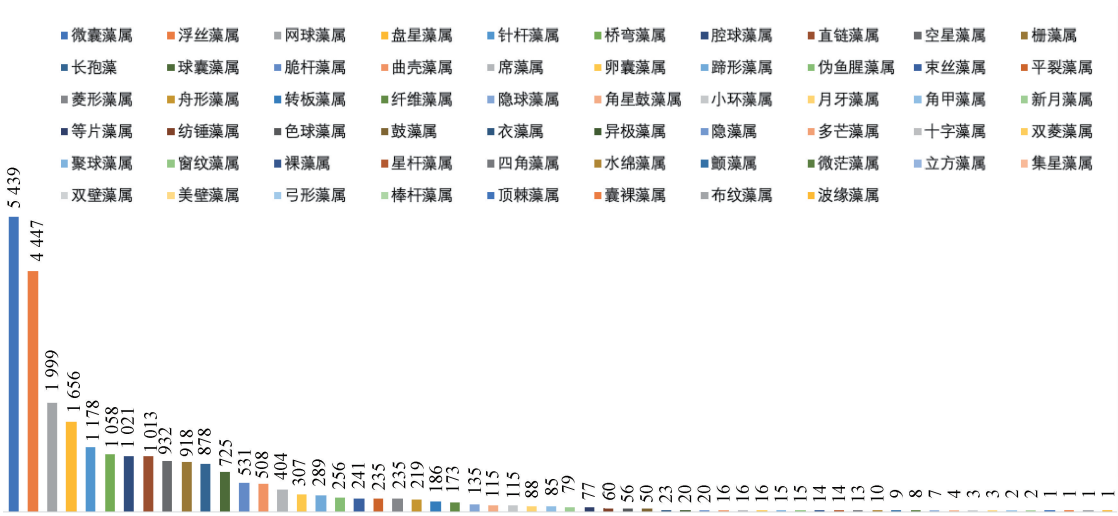

图 4 藻类标签数量分布图

Fig. 4 Distribution map of the number of algae labels

3.2　实验环境和训练参数

实验软件环境：Windows11 系统，Python3. 8 编程语言；硬件环境：12th Gen Intel（R） Core（TM） i5-12400F 2. 50 GHz CPU，内存大小 16 GB，GPU 为 Nvidia Geforce RTX3060。训练 600 个 Epoch，初始学习率设置为 0. 001。最小批次量设置为 16，衰减速率设置为 5×10^{-4}。

3.3　评价指标

在模型检测精度方面，为了客观地评价 YOLOv5 在改进前后的差异，选取了平均精度均值（mean average precision，mAP）作为评价指标；为了更全面地评估模型，还选取了平均精度均值、模型参数量和浮点运算次数（FLOPs）作为评价指标，用于评估检测精度、模型大小和计算复杂度。

3.4　消融实验

进行消融实验来验证本文算法对 YOLOv5s 的优化作用。表 1 为消融实验结果对比。表中 YOLOv5s-DRS 表示设计了一个反向采样器，并采用了延迟重采样方法；YOLOv5s-MobileNetV3 表示将 YOLOv5s 的 Backbone 替换为了 MobileNetV3；YOLOv5s-Distill-MobileNetV3 表示对轻量化的网络作了知识蒸馏。分别比较了算法的参数量、浮点运算次数以及 mAP。

从表 1 可见，DDM-YOLO 模型的参数量最少，浮点运算次数最少，但精度远高于同参数量，同浮点运算次数的模型。相比与初始模型，它的平均精度均值提高了 6. 1%，模型参数量减少了 3.23×10^{6}，浮点数计算削减了 9.6×10^{6}。相比与未压缩的 YOLOv5s-DRS 模型，它的平均精度均值只降低了 2. 1%。为了验证延迟重采样 DRS 的有效性，选择了 YOLOv5s 和 YOLOv5s-DRS 两个模型，并对它们在不同类别上的预测进行统计，分别比较了精确度、召回率以及 mAP。这里根据藻类显微图像数据集的藻类标签数量，分别划分头部藻类（标签数多于 500），中部藻类（标签数在 50 到 500 之间）以及尾部藻类（标签数少于 50），如表 2 所示，尽管 YOLOv5s 在检测头部藻类时表现较好，但在尾部藻类的检测上，mAP@0. 5 低至 0. 643，与头部藻类的检测效果相比，尾部藻类的各项指标均显著偏低。YOLOv5s-DRS 模型对尾部藻类的检测性能提升非常显著，提升幅度约为 20%。

表 1　消融实验结果对比

Table 1　Comparison of melting experiment results

方法	mAP@0. 5/%	Parameters/M	FLOPs/G
YOLOv5s	71. 0	7. 11	16. 5
YOLOv5s-MobileNetV3	66. 1	3. 88	6. 9
YOLOv5s-Distill-Mobilenetv3	69. 6	3. 88	6. 9
YOLOv5s-DRS（本文）	**79. 2**	7. 11	16. 5
DDM-YOLO（本文）	77. 1	**3. 88**	**6. 9**

表 2　YOLOv5s-DRS 与 YOLOv5s 对不同类别的检测结果

Table 2　YOLOv5s-DRS and YOLOv5s detection results for different categories

方法	Category	Accuracy/%	Recall/%	mAP@0. 5/%	mAP@0. 5:0. 95/%
YOLOv5s	All	78. 1	64. 3	71. 0	34. 3
	Head	81. 8	70. 2	76. 2	37. 3
	Middle	78. 8	63. 2	72. 4	34. 4
	Tail	73. 6	60. 3	64. 3	31. 2
YOLOv5s-DRS	All	79. 1	76. 4	79. 2	39. 3
	Head	83. 1	76. 2	80. 9	39. 2
	Middle	79. 4	77. 3	79. 4	39. 5
	Tail	74. 8	76. 5	77. 2	39. 1

根据图 5 所示的部分测试图片上的检测结果，YOLOv5s、YOLOv5s-MobileNetV3、YOLOv5s-Distill-MobileNetV3 模型都出现了不同程度的漏检或误检现象，例如第 1 行（a）图中，由于隐藻属是该数据集的尾部藻类，没有对隐藻属进行准确检测；第 3 行（c）图中，由于新月藻属和针杆藻属都是比较细长的藻类，没有对新月藻属进行准确检测。相对而言，本文提出的方法对微藻显微图像中不同种类的微藻能够有效地检测出来，其中 YOLOv5s-DRS 模型检测出的目标置信度最高。

3.5　不同模型对比分析

为了进一步准确且客观地验证本文所提出算法的先进性，将本文模型与其他主流算法的性能进行比较，其中包括其他解决长尾分布问题的常用方法如 FL（focal loss）、CB（class-balanced loss）和 EFL（equalized focal loss），并考虑平均精度均值、模型参数量和浮点运算次数等方面的综合性能，实验结果如表 3 所示。从表 3 可见：DDM-YOLO 模型的参数量和浮点运算次数大幅低于 YOLOv3[27]、YOLOv5s、YOLOv5s-FL、YOLOv5s-CB、YOLOv5s-EFL 和 YOLOv8 模型，并且 DDM-YOLO 模型相比于其他模型，取得了最高检测精度，综合 mAP、模型参数量和浮点运算次数来看，DDM-YOLO 有更好的性能。

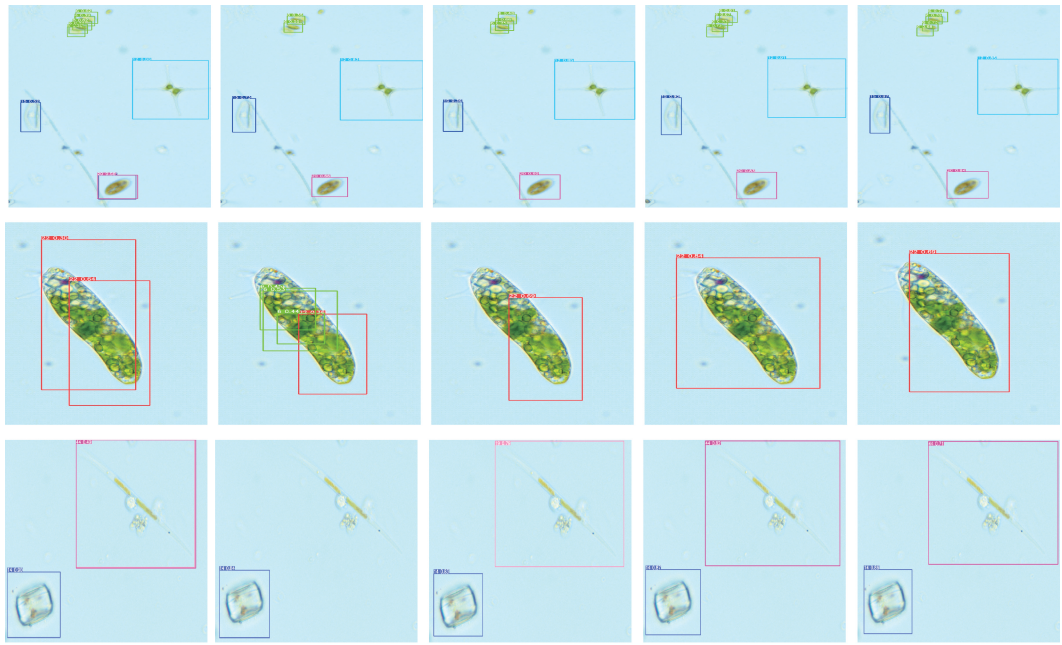

(a) YOLOv5s (b) YOLOv5s-MobileNetV3 (c) YOLOv5s-Distill-MobileNetV3 (d) YOLOv5s-DRS (本文) (e) DDM-YOLO (本文)

图 5 不同算法的部分微藻检测结果

Fig. 5 Some microalgae detection results of different algorithms

表 3 不同算法实验结果对比

Table 3 Comparison of algorithm experiment results

方法	mAP@0.5/%	Parameters/M	FLOPs/G
YOLOv3	68.8	61.8	156.2
YOLOv5s	71.0	7.11	16.5
YOLOv5s-FL	71.7	7.11	16.5
YOLOv5s-CB	72.0	7.11	16.5
YOLOv5s-EFL	72.2	7.11	16.5
YOLOv8	73.2	11.15	28.6
DDM-YOLO(本文)	**77.1**	**3.88**	**6.9**

4 结 论

本文提出了一种基于延迟重采样和知识蒸馏相结合的目标检测算法 DDM-YOLO。该模型在微藻显微图像数据集上的平均精度均值为 77.1%,模型参数量为 3.88×10^6,浮点数计算量为 6.9×10^6。所提出的方法在微藻显微图像数据上取得了显著的性能提升,同时在资源受限条件下实现了高效的目标检测,大大降低了检测人员的工作量。

采用延迟重采样,在二阶段采用反向采样,着重关注难以分类的少数类别样本,以改善目标检测性能,在不增加模型参数量和 FLOPs 的情况下,平均精度均值提高了 8.2%;将 MobileNetV3 作为 YOLOv5 模型的主干特征提取网络,为了减少检测精度损失,使用了知识蒸馏,平衡了模型参数量和检测精度。

DDM-YOLO 模型相对于 YOLOv3、YOLOv5s 和 YOLOv8 等模型在微藻检测上,提高了平均精度均值,同时减少了模型参数量和 FLOPs。这显示了 DDM-YOLO 模型在微藻检测中的优越性,并适宜在移动设备上部署。

参考文献

[1] ZHENG X, DUAN X, TU X, et al. The fusion of microfluidics and optics for on-chip detection and characterization of microalgae [J]. Micromachines, 2021, 12(10): 1137.

[2] FULBRIGHT S P, ROBBINS-PIANKA A, BERG-LYONS D, et al. Bacterial community changes in an industrial algae production system[J]. Algal Research, 2018, 31: 147-156.

[3] WU D, LI R, ZHANG F, et al. A review on drone-based harmful algae blooms monitoring [J]. Environmental Monitoring and Assessment, 2019, 191(4): 211.

[4] NING H, LI R, ZHOU T. Machine learning for microalgae detection and utilization [J]. Frontiers in Marine Science, 2022, 9: 947394.

[5] OTÁLORA P, GUZMÁN J L, ACIÉN F G, et al. Microalgae classification based on machine learning techniques[J]. Algal Research, 2021, 55: 102256.

[6] CAO M, WANG J, CHEN Y, et al Detection of microalgae

objects based on the Improved YOLOv3 model [J]. Environmental Science: Processes & Impacts, 2021, 23(10): 1516-1530.

[7] 王攀. 基于改进卷积神经网络的藻类图像分类研究[D]. 南昌:南昌航空大学, 2018.
WANG P. Research on algae image classification based on improved convolutional neural network [D]. Nanchang:Nanchang Hangkong University, 2018.

[8] 崔雪森, 田晓清, 康伟, 等. 基于卷积神经网络的微藻种类识别[J]. 上海海洋大学学报, 2021, 30(4): 710-717.
CUI X S, TIAN X Q, KANG W, et al. Recognition of microalgae species based on convolutional neural network [J]. Journal of Shanghai Ocean University, 2021, 30(4): 710-717.

[9] 王羽徵, 程远, 毕海, 等. 基于深度学习 VGG 网络模型的海洋单细胞藻类识别算法[J]. 大连海洋大学学报, 2021, 36(2): 334-339.
WANG Y ZH, CHENG Y, BI H, et al. Recognition algorithm for marine single-celled algae based on deep learning VGG network model [J]. Journal of Dalian Ocean University, 2021, 36(2): 334-339.

[10] 张志栋. 深度学习在水体藻类实时监测中的应用[D]. 哈尔滨:哈尔滨工业大学, 2020.
ZHANG ZH D. The application of deep learning in real-time monitoring of aquatic algae [D]. Harbin: Harbin Institute of Technology, 2020.

[11] 王晓阳. 基于图像的海洋微藻识别系统的设计与实现[D]. 大连: 大连海洋大学, 2020.
WANG X Y. Design and implementation of an image-based marine microalgae recognition system [D]. Dalian: Dalian Ocean University, 2020.

[12] QIAN P, ZHAO Z, LIU H, et al. Multi-target deep learning for algal detection and classification[C]. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). IEEE, 2020: 1954-1957.

[13] 吴志高, 陈明. 基于改进 YOLO v7 的微藻轻量级检测方法[J]. 大连海洋大学学报, 2023, 38(1): 129-139.
WU ZH G, CHEN M. Lightweight detection method for microalgae based on improved YOLO v7 [J]. Journal of Dalian Ocean University, 2023, 38(1): 129-139.

[14] 马燕婷, 赵红东, 阎超, 等. 改进 YOLOv5 网络的带钢表面缺陷检测方法[J]. 电子测量与仪器学报, 2022, 36(8): 150-157.
MA Y T, ZHAO H D, YAN CH, et al. Surface defect detection method for steel strip based on improved YOLOv5 network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 150-157.

[15] 龙乐云, 周腊吾, 刘淑琴, 等. 改进 YOLOv5 算法下的输电线路外破隐患目标检测研究[J]. 电子测量与仪器学报, 2022, 36(11): 245-253.
LONG L Y, ZHOU L W, LIU SH Q, et al. Research on transmission line external hazard detection based on improved YOLOv5 algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 245-253.

[16] 吕禾丰, 陆华才. 基于 YOLOv5 算法的交通标志识别技术研究[J]. 电子测量与仪器学报, 2021, 35(10): 137-144.
LYU H F, LU H C. Research on traffic sign recognition technology based on YOLOv5 algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 137-144.

[17] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.

[18] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.

[19] JAMAL M A, BROWN M, YANG M H, et al. Rethinking class-balanced methods for long-tailed visual recognition from a domain adaptation perspective[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 7610-7619.

[20] WANG H, WANG Y, ZHOU Z, et al. Cosface: Large margin cosine loss for deep face recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 5265-5274.

[21] CUI Y, JIA M, LIN T Y, et al. Class-balanced loss based on effective number of samples[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9268-9277.

[22] BUDA M, MAKI A, MAZUROWSKI M A. A systematic study of the class imbalance problem in convolutional neural networks [J]. Neural Networks, 2018, 106: 249-259.

[23] VERMA V, LAMB A, BECKHAM C, et al. Manifold mixup: Better representations by interpolating hidden states [C]. International Conference on Machine Learning. PMLR, 2019: 6438-6447.

[24] 李丹, 王慢慢, 刘俊德, 等. 基于轻量级卷积神经网

络的带钢表面缺陷识别[J]. 仪器仪表学报, 2022, 43(3): 240-248.
LI D, WANG M M, LIU J D, et al. Recognition of steel strip surface defects based on lightweight convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 240-248.

[25] 梁继然, 陈壮, 董国军, 等. 结合注意力机制和密集连接网络的车辆检测方法[J]. 电子测量与仪器学报, 2022, 36(3): 210-216.
LIANG J R, CHEN ZH, DONG G J, et al. Vehicle detection method combining attention mechanism and dense connection network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(3): 210-216.

[26] CHEN D, MEI J P, ZHANG Y, et al. Cross-layer distillation with semantic calibration[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(8): 7028-7036.

[27] FARHADI A, REDMON J. YOLOv3: An incremental improvement [C]. Computer Vision and Pattern Recognition. Berlin/Heidelberg, Germany: Springer, 2018, 1804: 1-6.

作者简介

汪鲁才,2006 年于湖南大学获得博士学位,现为湖南师范大学工程与设计学院教授,主要研究方向为图像处理与模式识别、语音信号处理、嵌入式系统及应用等。
E-mail: wanglucai@ hunnu. edu. cn

Wang Lucai received his Ph. D. degree from Hunan University in 2006. Now he is a professor in the College of Engineering and Design at Hunan Normal University. His main research interests include encompassing image processing and pattern recognition, speech signal processing, embedded systems and their applications, etc.

陈春江,2021 年于西华师范大学获得学士学位,现为湖南师范大学工程与设计学院硕士研究生,主要研究方向为图像处理。
E-mail: ccj1921352379@ 163. com

Chen Chunjiang received his B. Sc. degree from China West Normal University in 2021. Now he is a M. Sc. candidate at the College of Engineering and Design, Hunan Normal University. His main research interest includes image processing.

邹伊雯,2022 年于武汉工程大学获得学士学位,现为湖南师范大学工程与设计学院硕士研究生,主要研究方向为图像处理。
E-mail: 2608598881@ qq. com

Zou Yiwen received her B. Sc. degree from Wuhan Institute of Technology in 2022. Now she is a M. Sc. candidate at the College of Engineering and Design, Hunan Normal University. Her main research interest includes image processing.

谢婷(通信作者),2020 年于湖南大学获得博士学位,现为湖南师范大学工程与设计学院副教授,主要研究方向为图像处理、人工智能等。
E-mail: xieting@ hunnu. edu. cn

Xie Ting (Corresponding author) received her Ph. D. degree from Hunan University in 2020. Now she is an associate professor in the College of Engineering and Design at Hunan Normal University. Her main research interests include image processing and artificial intelligence.