doi:10.6041/j.issn.1000-1298.2020.09.019

基于联动扩展神经网络的水下自由活蟹检测器研究

赵德安[1]　曹　硕[1]　孙月平[1]　戚　浩[1]　阮承治[2]

(1.江苏大学电气信息工程学院,镇江 212013;2.武夷学院机电工程学院,武夷山 354300)

摘要:利用机器视觉技术检测池塘水下自由活蟹的形态位置和数量分布信息,是实现自动投饵船精准变量投喂的关键。本文设计了一种基于联动扩展卷积神经网络的实时轻量型水下活蟹检测器。首先,针对水下图像模糊和色彩不均的特点,以及稀疏分解后不同频率图像的信息组成特点,分别进行 K-SVD 降噪和 Retinex 色彩校正;然后,采用联动扩展网络宽度、深度和分辨率方式来协调精度和效率的轻量级 EfficientNet 作为主干网络;引入复合缩放因子,对堆叠两层加权双向特征金字塔结构的高效融合特征网络和堆叠三层卷积模块的类别/边界框预测网络进行全局联动扩展,以构建适用于有限资源的小型活蟹检测器;最后,在类别/边界框预测网络中利用正交 Softmax 层替代完全连接的分类层,确保检测器可从小样本数据中学习更多的区分特征,有效缓解小样本检测的过拟合问题。采用自建的 20 625 幅数据样本对检测模型进行训练和测试,实验表明,降噪、校正后的图像颜色均衡,且清晰度高,检测的平均交并比 I_{ou} 提高近 8 个百分点。检测模型 EfficientNet-Det0 存储内存仅需 15 MB,便可实现查准率 96.21% 和查全率 94.86%,单幅图像检测延迟分别为 10.6 ms(GPU)和 35.0 ms(CPU)。浮点运算次数 F_{LOPs} 减少至 YOLOv3 算法的 1/15,CPU 运行速度是其 3 倍,而准确性与 YOLOv3 算法相当,甚至略优。EfficientNet-Det0 搭载在资源受限的自动投饵船上能够快速精准检测水下河蟹,并能实现对池塘自由活蟹分布的统计,为建立科学的投喂机制提供可靠的决策信息。

关键词:自由活蟹检测;水下图像;颜色校正;卷积神经网络;联动扩展

中图分类号:TP391.4　　**文献标识码**:A　　**文章编号**:1000-1298(2020)09-0163-12　　**OSID**:

Small-sized Efficient Detector for Underwater Freely Live Crabs Based on Compound Scaling Neural Network

ZHAO Dean[1]　CAO Shuo[1]　SUN Yueping[1]　QI Hao[1]　RUAN Chengzhi[2]

(1. *School of Electrical and Information Engineering*, *Jiangsu University*, *Zhenjiang* 212013, *China*
2. *School of Mechanical and Electrical Engineering*, *Wuyi University*, *Wuyishan* 354300, *China*)

Abstract: Using machine vision technology to detect the morphological position and quantity distribution information of underwater freely live crabs in the pond is a key step to realize the precise variable feeding for automatic feeding boats. However, it is very challenging to detect crabs quickly and reliably in the underwater images because of the large differences in posture, similarity joints of crabs, and the uneven color characteristics of the underwater images. For this reason, a real-time lightweight underwater live crab detector based on compound scaling convolutional neural networks was proposed. Firstly, aiming to the characteristics of underwater image blur and color imbalance, K-SVD denoising and Retinex color-correction enhancement were performed respectively according to the information composition characteristics with different frequencies after sparse decomposition. Secondly, a lightweight EfficientNet that perfectly coordinated the accuracy and efficiency by compound scaling the network width, depth and resolution was adopted as the backbone network. After that, a compound scaling factor was introduced to perform global overall compound scaling of the efficiently integrated feature network, which stacked two-layer weighted bi-directional feature pyramid structures, and the class/boundary-box prediction network

收稿日期:2020-05-12　修回日期:2020-06-26

基金项目:国家自然科学基金项目(61903288)、江苏省自然科学基金项目(BK20170536)、福建省自然科学基金项目(2018J01471)、常州市现代农业科技项目(CE20192006)和江苏省高校优势学科建设项目(PAPD)

作者简介:赵德安(1956—),男,教授,博士生导师,主要从事智能控制和智能机器人研究,E-mail:dazhao@ujs.edu.cn

通信作者:孙月平(1982—),男,副教授,主要从事农业电气化与自动化装置研究,E-mail:sunypujs@ujs.edu.cn

that stacked three-layer convolution modules, to build a small-sized efficient detector for limited resources. In the class/boundary-box prediction network, an orthogonal Softmax layer was also adopted to replace the fully-connected classification layer to ensure that the detector can learn more distinguishing features from the small-sample dataset, which effectively alleviated the over-fitting problem of small-sample detection and improved the generalization ability of detectors. The model was trained and tested with self-built 20 625 data samples. Experiments showed that images after denoising and correction were color-balanced and high-definition, and the detection I_{ou} was increased by nearly 8 percentage points. The training detection model EfficientNet - Det0 can achieve 96.21% precision and 94.86% recall rate where only 15 MB storage memory was needed; the detection delay of a single image was only 10.6 ms (GPU) and 35.0 ms (CPU). Compared with the YOLOv3 algorithm, F_{LOPs} was reduced to 1/15, and operating speed of CPU was increased by 2 times, yet the accuracy was comparable to or even better than YOLOv3. The EfficientNet - Det0 proposed was suitable for applying on resource-restricted automatic feeding bait to quickly and accurately detect underwater live crabs, which could realize the statistics of the distribution for freely live crabs in ponds, and provide reliable decision information for establishing scientific feeding mechanism.

Key words: freely live crab detection; underwater image; color correction; convolutional neural network; compound scaling

0 引言

河蟹是重要的养殖水产品,其营养丰富,经济价值高。目前全国河蟹养殖总产值超过 550 亿元,养殖区域以长江中下游为主,产量占全国总产量的 80% 以上,现已成为我国渔业生产中发展最为迅速、最具有潜力的产业[1-2]。但是,河蟹养殖严重依赖人工,其集约化程度低、机械化自动化水平低,由于人工粗放喂养冰鱼、螺蛳等饲料的随机性,严重影响了河蟹养殖效益,甚至导致池塘水质恶化。因此,为了适应河蟹的养殖需求,节约占养殖总成本 60% 以上的饵料成本,迫切需要提高河蟹养殖的自动化及智能化水平[3]。目前,围绕河蟹自动投饵船的导航定位和均匀投饵等方面已有相关研究[1-3]。针对自动化领域中视觉引导智能化机械进行精准作业的潜在市场[4-5],考虑到传统投喂决策主要取决于人工经验和简单定时控制的局限性[6-7],采用机器视觉技术,由水下河蟹视频、图像来获取并提供池塘螃蟹的形态位置和数量分布信息,以进一步指导自动投饵船进行精确的变量投喂。

河蟹一般活动于 0.5 ~ 2.0 m 浅水池塘的底部和水草丛生的水域,水中含有杂质,由于透射光线的衰减导致水下采集的图像模糊、清晰度较低。同时,透射光也会由于吸收和散射随着距离和深度的增加呈指数衰减,导致波长最短的蓝光在水中传播时间最长,从而使水下图像主要呈现蓝绿色,并且不均匀[8]。研究发现,基于稀疏表达的图像降噪算法[9]和基于色彩理论的图像色彩校正增强算法[10]可在无需先验环境知识的情况下完全抽象出图像形成过程,可保证图像信息的可靠性,比图像恢复技术更简单、有效[11]。

河蟹尺寸小、肢体姿态差异大,蟹螯和蟹腿关节相似,且形状异常,使得传统的目标识别方法难以满足水下自由活蟹的检测需求[12-13]。基于方向梯度直方图(Histogram of oriented gradient, HOG)[14]、尺度不变特征转换[15]等方法,已逐渐转变为采用卷积神经网络(Convolutional neural networks, CNN)。提取抽象的高维特征、进行更加复杂的目标检测[16],比如在鱼类[17]、贝类[18]、海参[19]、果实[20]、牲畜[21]等目标的分类、定位、检测方面。YAO 等[19]利用空洞卷积和残留结构优化 MobileNet - SSD (Single shot multibox detector)的主干网络,将水下海参的检测速度提高到 43.65 f/s。LI 等[17]通过 Faster R - CNN (Regions with convolutional neural networks)共享 CNN 特征,以获取几乎免费的区域候选对象,加速了鱼类的检测和识别。MAZZIA 等[16]利用“Edge AI”的云端聚合服务解决嵌入式设备野外实时苹果检测需求,但这对网络通信要求较高,且云端服务价格昂贵。上述检测目标大都是形状相对规则的,并未涉及独立不规则的活蟹检测。而且,由于存储空间和功耗的限制,上述神经网络模型在移动设备中的存储和计算依然存在困难。赵德安等[7]采用 YOLOv3 (You only look once)在通用配置的微型计算机上实现了 10.67 f/s 的河蟹识别速度,但其识别模型的大小和参数量不是普通移动设备所能承受的。为了设计工业级轻量化的神经网络模型,可以考虑在保证或略微牺牲检测精度的前提下,从人工设计网络计算方式、神经网络架构搜索 (Neural architecture search, NAS)、卷积神经网络深度压缩和基于 AutoML 的自动模型压缩 4 方面[22]为移动设

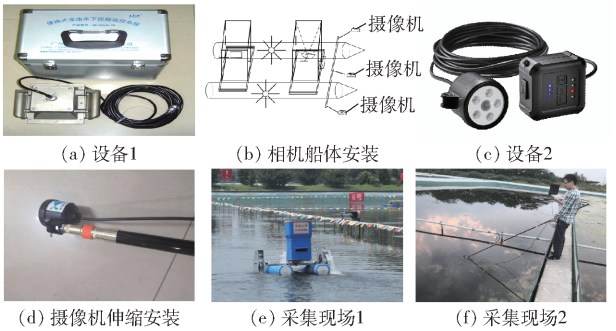
备部署小型轻量的神经网络模型。

根据自主开发的自动投饵船对池塘自由活蟹分布的统计需求，本文首先利用分解式并行降噪和色彩校正增强算法，对低质量图像进行简单有效的预处理，确保图像信息的可靠性，使其易于理解和分析；然后，采用基于联动扩展的 EfficientNet 作为活蟹检测器的主干网络，该主干网络分别从人工设计的 MBConv 基本计算模块、神经网络架构搜索的网络结构和伴随运算量约束的深度裁剪压缩 3 方面，构建能够限制目标计算量和存储空间的神经网络模型；最后，引入复合缩放因子，对高效融合的特征网络和类别/边界框预测网络进行全局的联动扩展，以构建适用于有限资源的精确、高效的活蟹检测器。

1　材料与方法

1.1　视频采集

实验图像采集自江苏省常州市长荡湖河蟹养殖基地。为适应河蟹夜间摄食习惯，避免过早投入的饵料因水浸泡而散开，不能被河蟹充分摄取而导致饵料浪费和水体污染，本文分别于傍晚和凌晨选取 3 个池塘进行视频采集。每个池塘水深 0.5 ~ 2.0 m，占地面积 16.7 km^2，每 0.7 km^2 投放约 1 000 只河蟹。图像采集设备 1 为 HB - HZSJC - YB 型便携式浑浊水下视频监控系统（图 1a），配有辅助照明光源 LED 灯。将其安装在自动投饵船上通过无线网络和有线连接方式采集能够反映池塘水下自然生活状态的活蟹视频（图 1b），视频分辨率为 1 920 像素 ×1 080 像素。图像采集设备 2 为配备 5 个高亮 LED 辅助照明灯的便携式水下浑浊摄像机（图 1c），主要用于从俯视视角采集处于隐匿环境的河蟹，弥补设备 1 的摄像头难以进入深水区进行平视拍摄的不足。图 1e 和图 1f 为傍晚时刻河蟹开始活动觅食时视频采集工作的现场。



(a) 设备1　(b) 相机船体安装　(c) 设备2

(d) 摄像机伸缩安装　(e) 采集现场1　(f) 采集现场2

图 1　视频采集系统

Fig. 1　Video acquisition system

1.2　数据集的制作与使用

数据集在很大程度上决定了训练的深度网络模型识别检测性能，其中数据的样本数量直接影响河蟹的检测精度。但真实的池塘环境复杂多变，使得水下河蟹图像采集的难度很大。本文通过逐帧方式处理采集的河蟹觅食视频，共选取 4 125 幅目标相对清晰且具有差异性和代表性的真实环境下的河蟹图像，用于模型的训练和测试。但是这样依然难以满足网络训练的需求，需要更大量的数据样本，否则依然会出现过度拟合的“高精度假象”。所以针对特定河蟹检测场景下数据集有限的情况，采用特定图像处理方式（几何角度：翻转、旋转、裁剪、缩放等；像素角度：亮度调节、对比度调节、噪声添加、通道变换等）来增加数据样本的数量与多样性，进一步提高模型的鲁棒性与泛化能力。最终建立了具有 20 625 幅水下河蟹图像的样本数据集。之后用 LabelImg 软件对最终完善后的数据集进行检测目标的矩形包围框标注。但是考虑到螃蟹有一对特征鲜明的蟹螯和 4 对特征相似的蟹腿，如果将它们全部框选，会使得矩形框标注的区域包含大量复杂各异的无用背景特征，从而在一定程度上干扰模型的训练、影响模型的性能。因此，在人工标注河蟹时，本文主要考虑河蟹的身体及一对特征鲜明的蟹螯，适当会包含部分蟹腿，标注情况如图 2 所示。最后按照通用数据集划分策略，将数据集随机分配成训练集（70%）、测试集（25%）和验证集（5%）。并将它们各自转换为只需一次性加载的 TFRecord 格式存储，这样能够有效加速数据读取，大幅提高数据处理效率。



(a) 单目标矩形框标签　(b) 多目标矩形框标签

图 2　河蟹鲜明特征的标记方式

Fig. 2　Special annotation way of river crab characteristics

1.3　活蟹检测器系统概述

图 3 为活蟹检测器的系统结构。首先，对呈现蓝绿色且伴随强烈不均匀色彩的输入标签图像进行分解式并行降噪和色彩校正增强。然后，将预处理后的标签图像映射到采用联动扩展网络深度、宽度和分辨率方式实现精度和效率协调的 EfficientNet - B0 主干网络，提取不同尺度的特征图像。接着，选取其中 5 层特征图作为堆叠双向特征金字塔网络（Bi-directional feature pyramid network，BiFPN）的输入来获取更高级别的融合特征图像。最后，将这些特征图输入堆叠三层卷积模块的类别/边界框预测网络以生成各种锚框。同时利用正交 Softmax 预测各种尺寸和纵横比锚框的坐标位置偏移量及其相

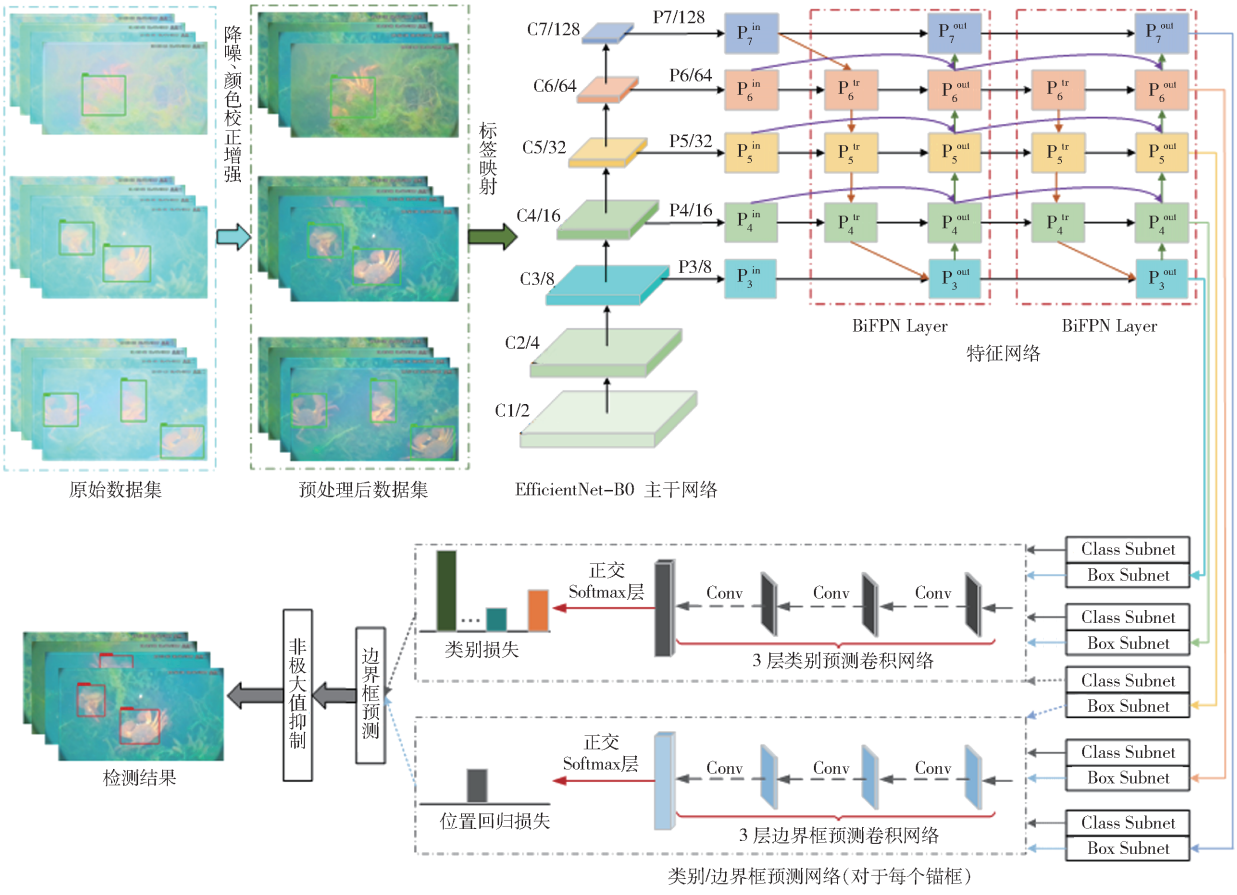


图 3 活蟹检测器系统结构图

Fig. 3 System structure of efficient live crab detector

关的置信度,从而得到预测边界框。图 3 中,P 表示金字塔融合特征图像分辨率级别,C 表示 MBConv Stage 输出特征图像分辨率级别。之后再将生成的所有预测边界框集合起来,通过设置重叠率阈值,采用非极大值抑制方法去除冗余重复的预测边界框。最终筛选保留比阈值具有更大置信度的需要输出的预测边界框,从而实时准确地获取包含河蟹类别、置信概率和边界框坐标的检测结果,如图 4 所示。

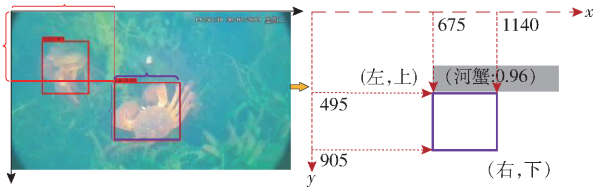


图 4 河蟹检测的详细参数

Fig. 4 Detailed parameters of crab detection

2 图像降噪与色彩校正

为确保图像信息的可靠性,提高水下河蟹的识别检测精度,对水下光学成像及照明环境特点进行分析,发现水下图像中纹理、边缘、细节等有用信息含有高频分量,同时噪声虽以高频分量为主但也会掺杂低频成分。这种在频率上的重叠特性是传统图像降噪方法无法有效去除噪声的主要原因,也是传统图像增强方法无法避开噪声干扰进行图像增强的主要原因[11]。因此,本文所提算法将 RGB 彩色原始图像(图 5a)分解为 R、G、B 三通道图像(图 5b),逐个提取 R、G、B 通道图像以进行有效去噪和颜色校正增强(图 6a)。在去噪和颜色校正增强过程中,首先应用形态成分分析[9]将一维通道图像按照不同的能量稀疏分解为含噪高频纹理图像和低频结构图像。然后按照不同频率图像的信息组成特点,应用 K-SVD (K-singular value decomposition)算法[9]对含有大部分噪声的高频纹理图像进行有效降噪,以较好保留河蟹纹理、边缘等有效信息。同时考虑到图像伴随着强烈不均匀的色彩现象,应用能够同时针对图像的动态范围压缩、边缘增强和颜色恒常进行平衡的 Retinex 算法[10],对几乎无噪的低频结构图像进行有效的增强和颜色校正,并且保证其目标结构不失真。对去噪和校正后的图像进行加性还原获得一维灰度通道分量(图 6b)。最后将处理后的 R、G、B 一维灰度通道图像融合恢复获得 RGB 彩色图像(图 5c)。图像清晰度显著提高,从而有利于图像理解与分析。颜色不均匀的区域相对原图有了明显的改善,避免了其对后续识别检测产生的干扰。

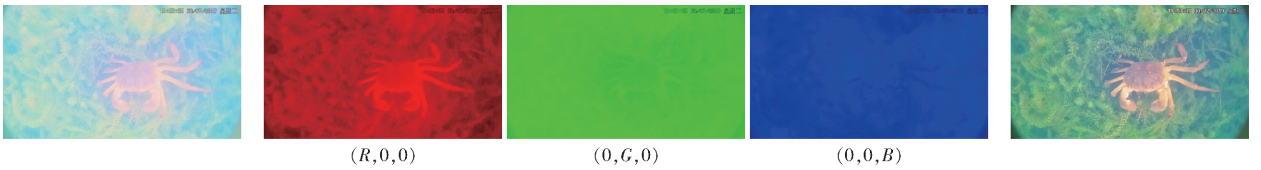


图 5　图像通道分解及融合过程

Fig. 5　Image channel decomposition and fusion process

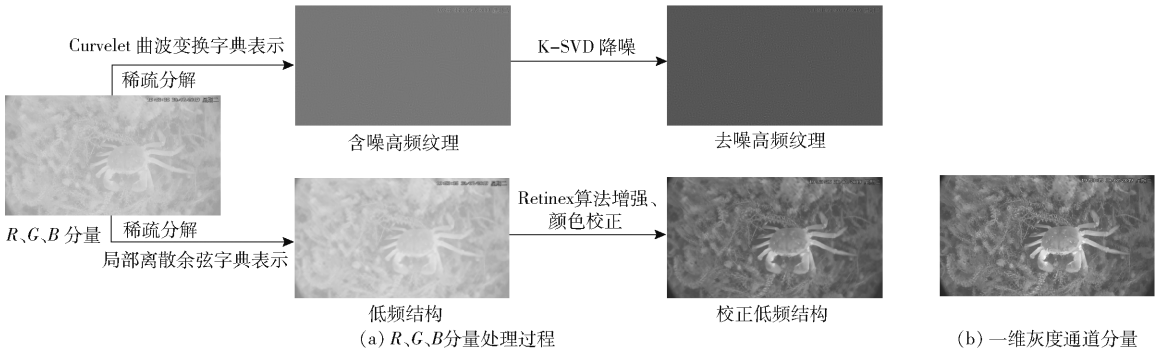


图 6　图像降噪与色彩校正过程

Fig. 6　Image denoising and color-correction enhancement process

3　两阶段联动扩展的活蟹检测

在计算量有限的移动嵌入式平台上，目前先进的检测网络往往不能达到实时性效果。极少数类似 Tiny YOLO 的网络能满足实时需求，但这类网络检测精度不高，同样不能达到需要的精度要求。本文在各类资源受限的条件下，局部联动扩展平衡所有维度信息的轻量级 EfficientNet 网络的基础上，采用全局联动扩展平衡检测器的主干网络、特征网络和类别/边界框网络，构建更加高效、更加精确的可收缩扩展检测器。

3.1　基于联动扩展的轻量级 EfficientNet 主干网络

扩展网络的深度（卷积层的数量）、宽度（卷积层的通道数）和分辨率（输入特征的尺寸）中的任一维度都可以提升精度（图 7），但常规扩展单一维度的模型会随着模型的增大，精度增益变小。为了获得协调的精度和效率，在神经网络扩展过程中综合平衡所有的维度信息是关键，所以 EfficientNet[23] 引入了扩展系数 θ 来联动统一扩展网络的深度、宽度和分辨率。

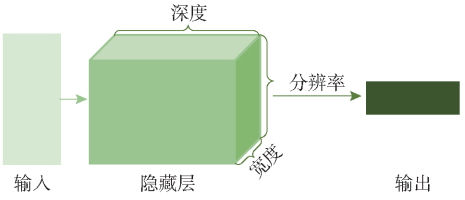


图 7　网络深度、宽度和分辨率的三维联动扩展结构

Fig. 7　Three-dimensional compound scaling structure of network depth, width and resolution

$$\begin{cases} d=\alpha^{\theta} \\ w=\beta^{\theta} \\ r=\chi^{\theta} \\ \text{s.t.} \begin{cases} \alpha\beta^{2}\chi^{2}\approx 2 \\ \alpha\geqslant 1 \\ \beta\geqslant 1 \\ \chi\geqslant 1 \end{cases} \end{cases} \tag{1}$$

式中　d——网络深度

w——网络宽度

r——网络分辨率

α——网络资源的深度分配系数

β——网络资源的宽度分配系数

χ——网络资源的分辨率分配系数

θ——用户指定的模型资源扩展系数

其中，α、β、χ 通过网络搜索暴力枚举得到最优解，θ 可根据模型可用资源进行调节，同时也表明资源的可用范围。α 增加一倍，浮点运算次数 F_{LOPs} 随之增加 2 倍；β 和 χ 增加一倍，F_{LOPs} 随之增加 4 倍。最终联动扩展操作使 F_{LOPs} 变为原来的 2^{θ} 倍。之后再以 MobileNetV2[24] 中的反向残差结构和压缩-激励优化[25] 构建的 MBConv（图 8）作为基本模块。通过神经网络架构搜索方式，在限制目标 F_{LOPs} 和存储空间的情况下，搜索得到一系列网络 EfficientNet B0 ~ B6。本文采用 EfficientNet - B0 网络作为模型的主干网络，网络参数如表 1 所示。在 stem stage 层考虑到小模型对前期底层特征的依赖性，未使用最大池化，而采用步长为 2 的卷积操作，可有效减少信息的丢失。其中多个 stage 都采用 5 × 5 的卷积核，这是

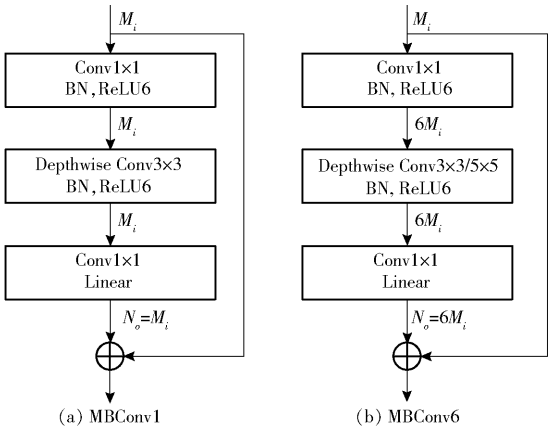


图 8 MBConv 基本单元架构

Fig. 8 MBConv architecture of basic unit

因为 MBConv 5×5 的浮点运算次数 F_{LOPs5} 比 2 个 MBConv 3×3 的浮点运算次数 F_{LOPs3} 小，而且大卷积核比小卷积核的效率高。

$$\frac{F_{LOPs5}}{2F_{LOPs3}}=\frac{HWM_i(5\times5\times1+1\times1\times N_o)}{2HWM_i(3\times3\times1+1\times1\times N_o)}=\frac{25+N_o}{18+2N_o}\leqslant1 \tag{2}$$

式中 H——输入/输出特征图的高度

W——输入/输出特征图的宽度

M_i——输入特征图的通道数

N_o——输出特征图的通道数

最后，某些 stage 特征图的分辨率和不规则的通道数都未改变，这是 MnasNet[26] 在搜索网络结构时因运算量约束而形成的。

表 1 轻量级 EfficientNet－B0 主干网络参数

Tab. 1 Lightweight EfficientNet－B0 backbone network parameters

卷积阶段	参数	分辨率/(像素×像素)
Stem Stage	Conv3×3，通道数为 32，步长为 2	224×224
MBConv Stage1	MBConv1，卷积核为 3×3，通道数为 16	112×112
MBConv Stage2	[MBConv6，卷积核为 3×3，通道数为 24]×2	112×112
MBConv Stage3	[MBConv6，卷积核为 5×5，通道数为 40]×2	56×56
MBConv Stage4	[MBConv6，卷积核为 3×3，通道数为 80]×3	28×28
MBConv Stage5	[MBConv6，卷积核为 5×5，通道数为 112]×3	28×28
MBConv Stage7	[MBConv6，卷积核为 5×5，通道数为 192]×4	14×14
MBConv Stage8	MBConv6，卷积核为 3×3，通道数为 320	7×7
Pooling Stage	Conv3×3，池化，全连接	7×7

3.2 二次联动扩展优化的小型检测器

EfficientNet－Detector 是 EfficientNet 网络的延续和发展，在各类资源受限的条件下，能构建一系列更加高效、更加精确的可扩展检测器[27]。完整的检测模型一般由 backbone 网络、特征网络和类别/框预测网络组成。在一次局部联动扩展 EfficientNet 主干的基础上，又从构建高效多尺度融合的 BiFPN[27] 和模型全局的二次联动扩展两方面出发，显著提高检测器的准确率，协调检测器的效率。

(1)高效多尺度融合 BiFPN

BiFPN 是在自顶向下通道融合的特征金字塔网络(Feature pyramid networks, FPN)[28] 和自底向上通道融合网络(Path aggregation network, PANet)[29] 的基础上，添加 NAS－FPN[30] 来搜索不规则拓扑结构(P4、P5、P6)，如图 9 所示。图中 P_3^{in} ~ P_7^{in} 是 BiFPN 的输入特征图，P_4^{tr} ~ P_6^{tr} 是中间融合特征图，P_3^{out} ~ P_7^{out} 是 BiFPN 的输出融合特征图。BiFPN 根据不同分辨率的特征直接相加融合对输出贡献的差异，为不同输入特征的学习引入了特征权重。在融合时采用快速归一化融合方法和深度可分离卷积[24]，并在每个卷积层后添加批归一化和激活函数[24]，确保提高融合效率。BiFPN 并非是一个网络特征结构，而是一种特征网络层，可以通过迭代这样的网络层来获取更高级别的融合特征。这样，类别/边界框预测网络就可以共享所有级别的特征，所以即便是形状不规则的河蟹目标也能实现很好的检测效果。

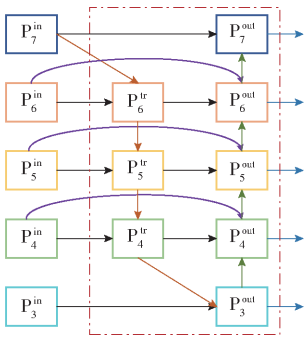


图 9 BiFPN 搜索的不规则拓扑结构图

Fig. 9 Irregular topology map of BiFPN search

(2)检测器模型的全局联动扩展

为了追求更高的检测精度，一般检测器模型的扩展大都只关注主干网络，往往忽略特征网络和类别/边界框预测网络的扩展。为此 EfficientNet－Detector 引入了一个简单的全局复合因子 ψ 来二次

统一联动扩展模型的 3 个构成部分[27]。具体而言，就是直接采用局部联动扩展后的最小型 EfficientNet－B0 作为主干网络。其次，线性增加 BiFPN 结构网络的深度，指数增加 BiFPN 结构网络的宽度。最后，保持类别/边界框预测网络的宽度与 BiFPN 结构网络的宽度相一致，只线性增加类别/边界框预测网络的深度。本文根据实时高效的检测需求，取全局复合因子 ψ 为 0，即堆叠 BiFPN 层 2 次、类别/边界框预测网络中的卷积模块 3 次。

$$d_{bi} = 2 + \psi \tag{3}$$

$$w_{bi} = 64 \times 1.35^{\psi} \tag{4}$$

$$w_{c/b} = w_{bi} \tag{5}$$

$$d_{class} = d_{box} = 3 + \psi/3 \tag{6}$$

式中　d_{bi}——BiFPN 的深度

w_{bi}——BiFPN 的宽度

$w_{c/b}$——类别/边界框预测网络的宽度

d_{class}——类别预测网络的深度

d_{box}——边界框预测网络的深度

(3)小样本正交 Softmax 分类层

深度学习可以通过大规模的图像样本取得巨大成功，但在许多实际问题中很难获取大规模数据。比如在池塘河蟹检测中，获取大规模可用于训练的水下图像数据不现实。所以采用小样本分类进行检测是最科学合理的做法，即只需要将样本粗略预测分类为河蟹和背景。但是在类别/边界框预测网络之前会经过很多个非线性层，这些层组成的深层神经网络会形成一个巨大的函数空间，在遇到小样本数据时会导致过拟合和不稳定的问题。为了减轻小样本分类检测过程中的过度拟合问题，需要从小样本数据中学习更多的区分特征。而利用正交 Softmax 层[31]替代完全连接的分类层，便能够找到一个可以轻松获取较大决策余量[32]并能学习高度区分性特征的神经网络子空间。具体来说，就是通过在输出分类层中减少一些连接，并在训练和测试过程中使不同类别的权重向量保持正交来获取较大的决策余量(图 10)。这是因为分类层中权重向量间的角度越大，泛化能力越好。最终由于减少了连接、增加了不同类间的角度，正交 Softmax 层可以减轻网络的协同适用，增强网络的辨识能力，从而有效缓解小样本检测的过拟合问题，大幅提高网络的泛化能力，增强检测器的鲁棒性。

4　实验

4.1　活蟹检测器训练与测试

检测模型的训练和测试硬件环境为 Intel E5 CPU，64 GB RAM，4 NVIDIA 1080 Ti GPUs，采用

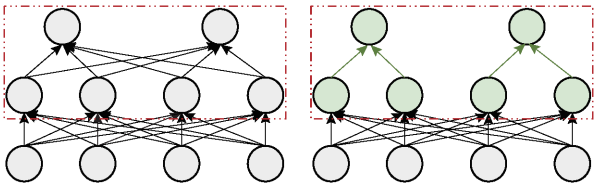


图 10　样本分类层的网络子空间连接的比较

Fig. 10　Comparison of network subspace connections in sample classification layer

Python3 编程语言和 PyTorch 深度学习框架实现。以图像为中心对高效活蟹检测器模型进行训练。检测器的各项训练超参数设置如表 2 所示，通过修改网络类别索引将检测器设置为仅保留河蟹类别的二分类检测模型。在训练过程中采用两种训练方式，一种是未做任何微调的直接训练，另一种是基于 Pre-training 和 Fine-tuning 的迁移训练。本文采用的迁移训练方式主要分为两阶段：第 1 阶段下载并加载 Pre-training 的权重，冻结主干网络训练；第 2 阶段冻结批归一化层，其余层开始训练。在第 2 阶段过程中，参数较大时依然可以冻结部分主干网络不让其全部参与训练。对河蟹检测器模型训练迭代了 12 900 次，这意味着将损失函数反向传播了 12 900 次，来调节网络各层的权值。训练损失值如图 11 所示，从图中可以明显观察到迁移训练的损失值相较于直接训练可以很快地趋于稳定的小值，并且损失值的毛刺波动较小。图 12 进一步证明了迁移学习能提高训练效率。最终本文采用迁移学习训练出了精确的检测器。

表 2　检测器的训练超参数

Tab. 2　Training parameters of detector

参数	含义	数值
带动量的梯度随机下降	通过在损耗的负梯度上采取较小的步幅来更新网络参数以最小化损失函数	0.9
最大迭代数	数据集完成完整传递的最大次数	10
迭代次数	迭代参数的更新次数	1 290
批尺寸	每次迭代的观察次数	16
权重衰减系数	有效避免过拟合的 L2 正则化系数	0.000 04
初始学习率	学习率预热 5% 步数	0 ~ 0.08
	Cosine 学习率衰减	0.997
焦点损失	正负样本比例平衡系数	0.25
	易分样本权重系数	1.5
迁移学习率	全局学习率	0.000 01
锚框比	矩形检测框的长宽比	{1/2,1,2}

4.2　图像降噪与颜色校正效果分析

为了验证采用 K－SVD 和 Retinex 算法进行降

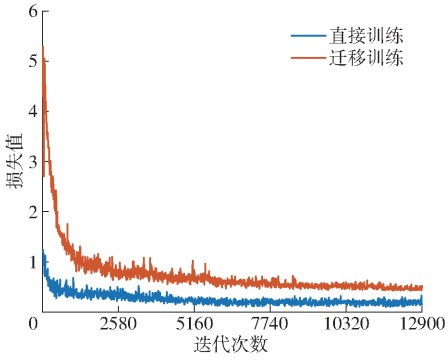


图 11 训练损失值曲线

Fig. 11 Training loss curves

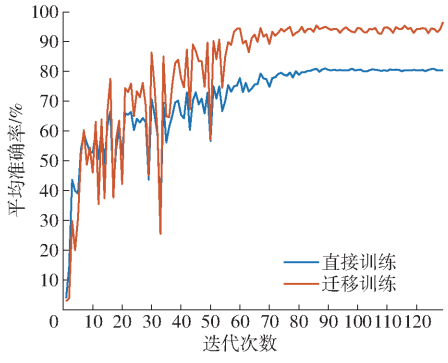


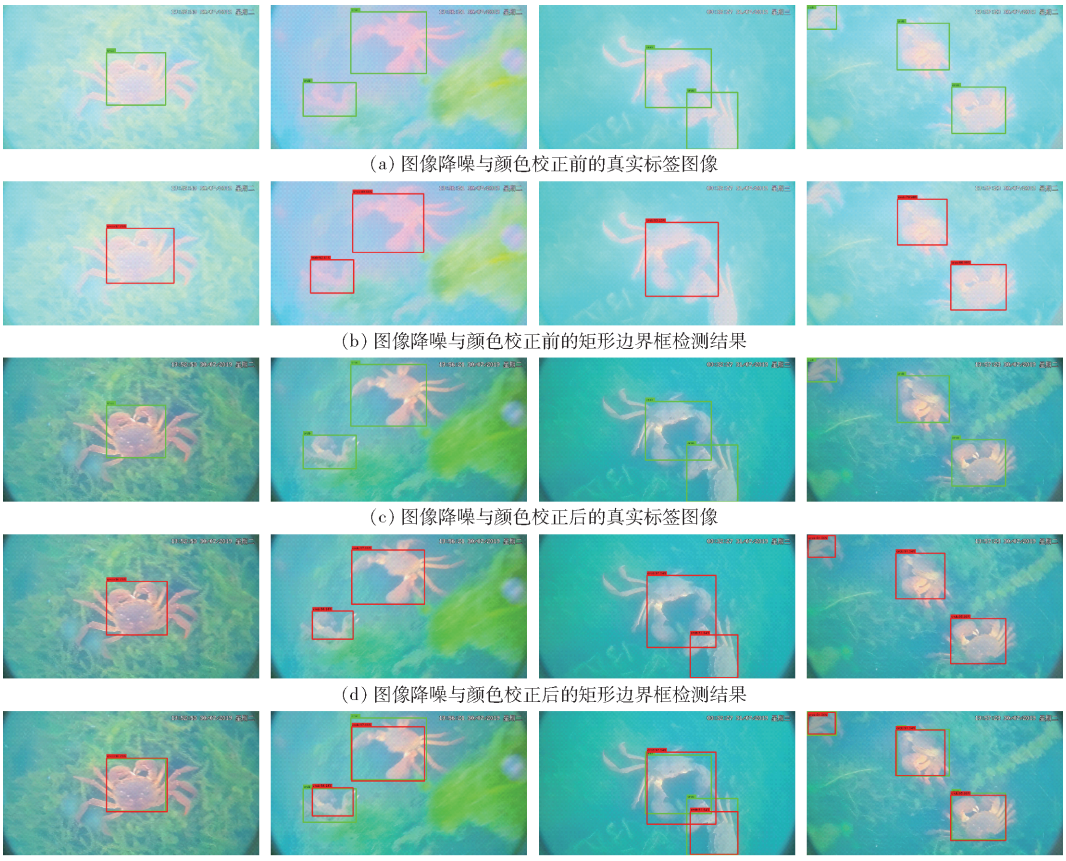
图 12 两种训练的平均准确率

Fig. 12 Average accuracy of two training methods

噪和颜色校正增强的效果与性能,对比处理前后的图像,发现处理后的图像整体更加清晰,这表明所用降噪方法进行了有效降噪且未破坏纹理信息;同时图像中河蟹与背景有了相对鲜明的对比,颜色不再呈现强烈不均匀,表明所用增强方法对图像进行了适当的颜色校正且未造成结构失真(图 13a、13b)。另一方面,分别利用预处理前后的数据训练检测模型并对测试集进行检测。两个模型的客观边界框检测数据显示,预处理前训练的模型针对多目标且相互遮挡的河蟹目标会出现漏检的情况(图 13b)。而预处理后训练的模型应用于各种场景时很少出现漏检和误检的情况(图 13d)。并且表 3 第 2 行所示降噪、颜色校正增强后的平均交并比 I_{ou} 相较第 1 行预处理前增加了 8.01 个百分点。单值 I_{ou} 更加地接近于 1,甚至出现某些矩形边界框的检测范围包含于标记的真值框(图 13e)。此外,表 3 显示预处理后河蟹检测精度提高了约 5 个百分点,误检河蟹数量明显减少。这些进一步证明了利用本文方法处理图像后,其特征信息易于计算机理解与分析,河蟹识别准确率更高。

4.3 检测器可靠性分析

为了测试 EfficientNet - Detector 对水下河蟹检测的可靠性,利用包含 2 192 只河蟹的 1 032 幅测试图像,分别从一次联动扩展的 EfficientNet 主干网络对特征的专注性和二次全局联动扩展的 EfficientNet -



(a) 图像降噪与颜色校正前的真实标签图像

(b) 图像降噪与颜色校正前的矩形边界框检测结果

(c) 图像降噪与颜色校正后的真实标签图像

(d) 图像降噪与颜色校正后的矩形边界框检测结果

(e) 图像降噪与颜色校正后的绿色真值框-红色检测矩形边界框

图 13 图像降噪与颜色校正前后的矩形边界框检测结果

Fig. 13 Rectangular-bounding box detection results before and after image denoising and color-correction

表 3　联动扩展和正交 Softmax 层对检测模型性能的影响

Tab. 3　Effects of compound scaling and orthogonal Softmax layer on performance of detection model

扩展系数 θ	复合因子 ψ	降噪、颜色校正	正交 Softmax	I_{ou}/%	戴斯系数 D_c/%	未检测到的河蟹数量 F_N/只	模型内存 M_s/MB	平均检测时间(GPU) F_{PS}/ms	平均检测时间(CPU) F_{PS}/ms
1	0			82.36	89.48	220	15.1	10.9	35.2
1	0	√		90.37	94.79	127	15.1	10.9	35.2
1	0	√	√	91.03	95.53	112	15.0	10.6	35.0
1	1			84.09	90.69	202	18.7	14.2	46.6
1	1	√		91.37	96.21	98	18.7	14.2	46.6
1	1	√	√	92.23	96.89	90	18.6	13.8	46.5
1↑	1↑	√	√	92.23↑	96.89↑	90↑	18.6↑	13.8↑	46.5↑

注：√和↑分别表示采用和升高。

Detector 对检测精度和速度的协调性两方面进行了分析。最后验证了正交 Softmax 分类层对模型泛化能力的作用。为了准确地分析、验证检测器的性能，需要采用多种客观评价标准从各个方面对其进行评判。评价指标为交并比 I_{ou}，用于衡量数据集上目标检测器的准确性，如果其值大于 50% 则认为检测结果可信。之后由查准率 P、查全率 R 和戴斯系数 D_c 对检测结果进行全面评估。戴斯系数 D_c 是查准率 P 和查全率 R 的调和平均值，是评估检测器检测准确性的标准化度量。上述指标的取值范围都在 0 ~ 100% 之间，并且其值越大越好。而对于检测效率的评估除了评估图像的平均检测时间 F_{PS}，还从模型的 F_{LOPs}、参数量 P_{ara} 和模型内存 M_s 进行了全面评估。

$$I_{ou} = \frac{O_A}{O_U} \times 100\% \tag{7}$$

$$P = \frac{T_P}{T_P + F_P} \times 100\% \tag{8}$$

$$R = \frac{T_P}{T_P + F_N} \times 100\% \tag{9}$$

$$D_c = \frac{2PR}{P + R} \tag{10}$$

式中　O_A——标记真值框与检测边界框的交集

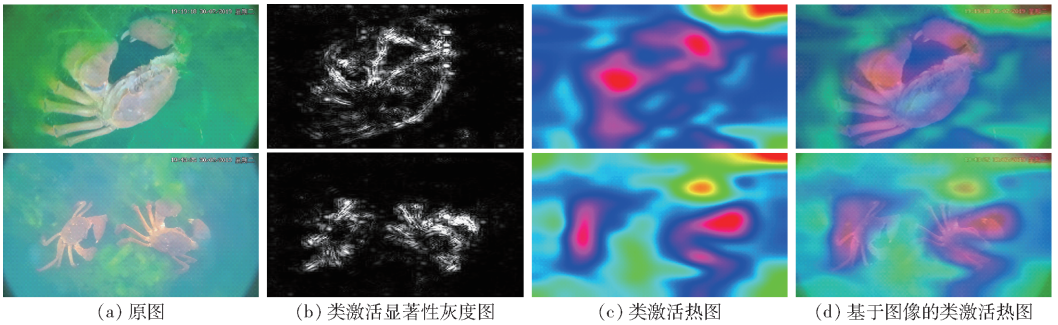
O_U——标记真值框与检测边界框的并集

T_P——正确检测的河蟹数量

F_P——错误检测的河蟹数量

F_N——在规定范围内未检测到的河蟹数量

通过对图 14 的分析发现，类激活显著性灰度图（图 14b）是通过河蟹全局的像素点感知图像类别的。而由图 14c 可以看出，蟹螯部分的类激活强度很高，河蟹其他部分的类激活强度平稳。这表明模型主要是通过图像中蟹螯部分的像素点实现河蟹目标的分类，进一步验证了矩形框标记蟹螯做法的正确性。最后图 14d 验证了在经过扩展系数 $\theta = 1$ 联动扩展后，参数量和 F_{LOPs} 小一个数量级的情况下，EfficientNet 主干模型可以更加显著地专注于更多目标的细节和更相关目标的图像区域。即便是相似的蟹腿也受到显著关注，这能够有效缓解活蟹不规则形状特征提取困难的问题。表 3 展示了联动扩展和正交 Softmax 层对检测模型的性能影响。通过对比表 3 中第 2 行和第 6 行数据发现，当全局整体联动扩展的复合因子 ψ 大于等于 1 时，检测器的精度检测指标都有约 2% 的提升。但也伴随着模型内存的增大以及检测时间的增加，不过这为具有不同有限资源的移动设备提供了灵活的选择需求。而考虑到自动投饵船的成本效益和资源限制情况，选择联动扩展程度最低的 EfficientNet - B0 和整体联动扩展复合因子最小的 EfficientNet - Det0 最合理，既适合投饵船移动端的需求又可获得较高的检测精度。最后对比表中数据发现，将检测器的分类层替换为正交 Softmax 层后，进一步增强了小样本网络的辨识能力。在仅需 15 MB 存储内存的情况下，检测模型 D_c 为 95.53%。在普通配置的 GPU 和 CPU 上，单幅图像检



(a) 原图　(b) 类激活显著性灰度图　(c) 类激活热图　(d) 基于图像的类激活热图

图 14　梯度加权的类激活图

Fig. 14　Gradient-weighted class activation maps

测延迟分别仅为 10.6、35.0 ms,能够满足水产养殖系统对现代设备平台处理频率(10 Hz)的实时需求。

4.4 检测器实用性分析

为了测试高效活蟹检测器 EfficientNet - Det0 对水下河蟹检测的实用性,将其与 YOLOv3[7]、Faster R - CNN[17]、SSD[8,11,19]算法以及传统的 HOG + SVM (Support vector machine)[14]检测方法进行比较,结果见表 4。

表 4 不同检测算法的检测参数比较

Tab. 4 Comparison of detection parameters for different detection algorithms

算法	P/%	R/%	D_c/%	P_{ara}	F_{LOPs}	M_s/MB	速度(GPU)/(f·s^{-1})	速度(CPU)/(f·s^{-1})
EfficientNet - Det0	96.21	94.86	95.53	3.900×10^6	2.530×10^9	15.0	94.00	28.60
YOLOv3	94.84	93.02	93.67	5.925×10^7	3.697×10^{10}	237.0	48.83	9.52
SSD - VGG16	96.73	93.89	95.29	3.425×10^7	1.550×10^{10}	137.0	9.30	2.35
SSD - MobileNetV1	94.58	94.32	94.45	5.490×10^6	2.980×10^9	21.6	14.66	3.68
Faster R - CNN	97.03	95.86	96.44	1.365×10^8	2.021×10^{11}	549.0	5.67	1.07
HOG + SVM	73.15	69.60	71.33				3.10	0.67

通过表 4 数据分析发现,EfficientNet - Det0 采用 BiFPN 的拓扑快速特征融合机制,其查准率比 YOLOv3 高 1.37 个百分点。虽然与 Faster R - CNN 算法的查准率存在一定的差距,但 EfficientNet - Det0 的查准率与模型性能可以通过主干网络 EfficientNet 的扩展系数 θ 和模型的联动扩展复合因子 ψ 进行有效的优化、权衡和取舍。相较于 YOLOv3 算法,F_{LOPs}减少至其 1/15、运行速度是其 3 倍的情况下,本文算法实现了查准率 96.21% 和查全率 94.86%。相较于 SSD - VGG16 和 SSD - MobileNetV1 算法,EfficientNet - Det0 在模型存储空间上分别约为其 1/9 和 5/7。这是因为 SSD - VGG16 和 SSD - MobileNetV1 算法仅从多尺度特征网络和人工设计主干网络计算方式(深度可分离卷积)方面单一地提升网络性能。而 EfficientNet - Det0 是从构成模型的 3 个主要部分共同提升,并且在提升的过程中采用了人工设计网络计算方式(MBConv 单元)、神经网络架构搜索(MnasNet 搜索)、卷积神经网络深度压缩(裁枝)3 种轻量化设计思想。相较于 HOG + SVM 方法,EfficientNet - Det0 在各方面都有着显著的优势,这是因为 HOG + SVM 方法提取的方向梯度直方图特征仅适合规范且具有方向性的目标,而河蟹姿态各异、形状不规则。此外,河蟹的这类特点也进一步加剧了 SVM 高维分类的困难。EfficientNet - Det0 采用的是卷积神经网络,能够学习、提取输入数据的局部区域特征,比如颜色、纹理、形状等低维特征。最重要的是能够学习、提取输入数据的深层抽象特征,比如图像中目标的属性、轮廓、位置等高维信息。而这类深层次的特征对图像中目标的形状、位置、大小、姿态、方向等并不敏感,所以能够确保面对独立不规则的复杂河蟹目标依然可以具有很高的识别检测率,从侧面验证了 EfficientNet - Det0 具有较高的鲁棒性。所以综合检测精度、计算速度、模型内存和鲁棒性来看,EfficientNet - Det0 对于计算资源有限的移动设备具有很好的实用性,是一种可靠的适合搭载在自动投饵船上进行水下河蟹检测、指导河蟹均匀投喂的算法。

5 结论

(1)利用分解式并行降噪和色彩校正算法对呈现蓝绿色且伴随强烈不均匀色彩的低质量图像进行了简单有效的预处理,显著提高了图像的清晰度,缓解了色彩不均匀性,保证了图像信息的可靠性,使其易于分析。

(2)采用局部联动扩展的 EfficientNet - B0 作为活蟹检测器的主干网络,采用拓扑且快速特征融合的 BiFPN 作为特征网络,采用基于锚框的类别/边界框作为预测网络。对模型进一步采用全局联动扩展,构建适用于有限资源的一系列高效检测器。通过建立的 20 625 幅图像数据集对模型进行训练和性能测试,在此过程中,针对小样本数据的过拟合问题,采用正交 Softmax 层进行了优化。训练的模型在仅需 15 MB 存储内存的情况下,实现查准率 96.21% 和查全率 94.86%,单幅图像检测延迟分别为 10.6 ms(GPU)和 35.0 ms(CPU)。

(3)实验对比了 3 类 6 种不同的检测算法,从检测精度、计算速度、模型内存和鲁棒性 4 方面验证了所训练的检测器的可靠性和实用性。本文算法相较于 YOLOv3 算法,浮点运算次数 F_{LOPs}减少至其 1/15,CPU 运行速度是其 3 倍,戴斯系数为 95.53%。

参 考 文 献

[1] 阮承治,赵德安,刘晓洋,等. 基于 IPSO－UKF 的水草清理作业船组合导航定位方法[J/OL]. 农业机械学报,2017,48(7):38－45.
RUAN Chengzhi, ZHAO Dean, LIU Xiaoyang, et al. Integrated navigation positioning method based on IPSO－UKF for aquatic plants cleaning workboat[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(7): 38－45. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20170705&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.07.005. (in Chinese)

[2] 宋迁红, 赵永锋. 2018 河蟹养殖产业现状及标准浅析[J]. 科学养鱼, 2018(10): 13－16.

[3] 孙月平, 赵德安, 洪剑青, 等. 河蟹养殖全覆盖自动均匀投饲的轨迹规划与试验[J]. 农业工程学报, 2016, 32(18): 190－200.
SUN Yueping, ZHAO Dean, HONG Jianqing, et al. Design of automatic and uniform feeding system carried by workboat and effect test for raising river crab[J]. Transactions of the CSAE, 2016, 32(18): 190－200. (in Chinese)

[4] FØRE M, FRANK K, NORTON T, et al. Precision fish farming: a new framework to improve production in aquaculture[J]. Biosystems Engineering, 2018, 173: 176－193.

[5] LUNA F D V B, DE LA ROSA A E, NARANJO J S, et al. Robotic system for automation of water quality monitoring and feeding in aquaculture shadehouse[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2016, 47(7): 1575－1589.

[6] 李道亮, 包建华. 水产养殖水下作业机器人关键技术研究进展[J]. 农业工程学报, 2018, 34(16): 1－9.
LI Daoliang, BAO Jianhua. Research progress on key technologies of underwater operation robot for aquaculture [J]. Transactions of the CSAE, 2018, 34(16): 1－9. (in Chinese)

[7] 赵德安, 刘晓洋, 孙月平, 等. 基于机器视觉的水下河蟹识别方法[J/OL]. 农业机械学报, 2019, 50(3): 151－158.
ZHAO Dean, LIU Xiaoyang, SUN Yueping, et al. Detection of underwater crabs based on machine vision[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 151－158. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20190316&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.03.016. (in Chinese)

[8] YAO J, HAN F, ZHU H. Underwater image processing and object detection based on modified YOLO method[C]// The 29th International Ocean and Polar Engineering Conference. International Society of Offshore and Polar Engineers, 2019.

[9] GOLLA M, RUDRA S. A novel approach of K－SVD-based algorithm for image denoising[M] // Histopathological Image Analysis in Medical Decision Making. IGI Global, 2019: 154－180.

[10] ZHUANG P, DING X. Underwater image enhancement using an edge-preserving filtering Retinex algorithm[J]. Multimedia Tools and Applications, 2020,79: 17257－17277.

[11] CAO S, ZHAO D, LIU X, et al. Real-time robust detector for underwater live crabs based on deep learning[J]. Computers and Electronics in Agriculture, 2020, 172: 105339.

[12] 郭传鑫, 李振波, 乔曦, 等. 基于融合显著图与 GrabCut 算法的水下海参图像分割[J/OL]. 农业机械学报, 2015, 46(增刊): 147－152.
GUO Chuanxin, LI Zhenbo, QIAO Xi, et al. Image segmentation of underwater sea cucumber using GrabCut with saliency map [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(Supp.): 147－152. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2015S025&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.S0.025. (in Chinese)

[13] 孙龙清, 刘婷, 陈帅华, 等. 多目标鱼体对象提议检测算法研究[J/OL]. 农业机械学报, 2019, 50(12): 260－267.
SUN Longqing, LIU Ting, CHEN Shuaihua, et al. Multi-target fish detection algorithm based on object proposals [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 260－267. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx ? flag=1&file_no=20191230&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.12.030. (in Chinese)

[14] RADMAN A, ZAINAL N, SUANDI S A. Automated segmentation of iris images acquired in an unconstrained environment using HOG－SVM and GrowCut[J]. Digital Signal Processing, 2017, 64: 60－70.

[15] RATNASAR R, IRAWAN B, SETIANINGSIH C. Traffic sign recognition application using scale invariant feature transform method and support vector machine based on Android[C] // 2017 IEEE Asia Pacific Conference on Wireless and Mobile (APWiMob). IEEE, 2017: 47－51.

[16] MAZZIA V, KHALIP A, SALVETTI F, et al. Real-time apple detection system using embedded systems with hardware accelerators: an edge AI application[J]. IEEE Access, 2020, 8: 9102－9114.

[17] LI X, SHANG M, HAO J, et al. Accelerating fish detection and recognition by sharing CNNs with objectness learning[C]// OCEANS 2016－Shanghai. IEEE, 2016: 1－5.

[18] LI G, LI Z, ZHANG C, et al. Shellfish detection based on fusion attention mechanism in end-to-end network[C]// Chinese Conference on Pattern Recognition and Computer Vision (PRCV). Springer, Cham, 2019: 516－527.

[19] YAO Y, QIU Z, ZHONG M. Application of improved MobileNet－SSD on underwater sea cucumber detection robot[C]//2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). IEEE, 2019: 402－407.

[20] 刘小刚, 范诚, 李加念, 等. 基于卷积神经网络的草莓识别方法[J/OL]. 农业机械学报, 2020, 51(2): 237－244.
LIU Xiaogang, FAN Cheng, LI Jianian, et al. Identification method of strawberry based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 237－244. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2002026&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.

2020.02.026. (in Chinese)
[21] 李丹, 张凯锋, 李行健, 等. 基于 Mask R-CNN 的猪只爬跨行为识别[J/OL]. 农业机械学报, 2019, 50(增刊): 261-266,275.
LI Dan, ZHANG Kaifeng, LI Xingjian, et al. Mounting behavior recognition for pigs based on Mask R-CNN [J/OL] Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 261-266,275. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2019s041&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.S0.041. (in Chinese)
[22] HE Y, LIN J, LIU Z, et al. AMC: AutoML for model compression and acceleration on mobile devices[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 784-800.
[23] TAN M, LE Q V. EfficientNet: rethinking model scaling for convolutional neural networks[J]. arXiv Preprint arXiv:1905.11946, 2019.
[24] SANDLER M, HOWARD A, ZHU M, et al. Mobilenet v2: inverted residuals and linear bottlenecks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
[25] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
[26] TAN M, CHEN B, PANG R, et al. MnasNet: platform-aware neural architecture search for mobile[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 2820-2828.
[27] TAN M, PANG R, LE Q V. Efficientdet: scalable and efficient object detection[J]. arXiv Preprint arXiv:1911.09070, 2019.
[28] LIN T Y, DOLLAR 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.
[29] 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.
[30] GHIASI G, LIN T Y, LE Q V. NAS-FPN: learning scalable feature pyramid architecture for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 7036-7045.
[31] LI X, CHANG D, MA Z, et al. OSLNet: deep small-sample classification with an orthogonal Softmax layer[J]. arXiv Preprint arXiv:2004.09033, 2020.
[32] LIU W, WEN Y, YU Z, et al. Large-margin Softmax loss for convolutional neural networks[C]// Proceedings of the 33rd ICML, 2016:507-516.

(上接第 185 页)

[29] NEO-7 u-blox 7 GNSS modules data sheet[EB/OL]. [2014-11-11]. https://www.u-blox.com/sites/default/files/products/documents/NEO-7_DataSheet_(UBX-13003830).pdf.
[30] LEE H W, CHEN X Z, TAN X H. The study of using arduino to control aircraft combined with obstacle avoidance warning function[C]//2018 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW). IEEE, 2018: 1-2.
[31] DE P L T, DE L V, PAIANO R. Sensor data collection and analytics with thingsboard and spark streaming[C]//2018 IEEE Workshop on Environmental, Energy, and Structural Monitoring Systems (EESMS). IEEE, 2018: 1-6.
[32] 秦永元. 惯性导航[M]. 北京:科学出版社,2006.
[33] PRATAQ M, PER E. Global positioning system-signals, measurements, and performance[M]. Massachusetts: Ganga-Jamusna Press, 2006.
[34] LOW Z N, LAW C L. Improving time to first fix for GPS receivers[D]. Singapore: Nanyang Technological University, 2015.
[35] PADEN B, ČAP M, YONG S Z, et al. A survey of motion planning and control techniques for self-driving urban vehicles[J]. IEEE Transactions on Intelligent Vehicles, 2016, 1(1): 33-55.
[36] STEVEN M LaV. Planning algorithms[M]. London: Cambridge University Press, 2006.
[37] ADRIAN K, GARY B. Learning OpenCV3: computer vision in C++ with the OpenCV library[M]. Massachusetts: O'Reilly Media Inc., 2016.
[38] HIRSCHMULLER H. Stereo processing by semiglobal matching and mutual information[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(2): 328-341.
[39] 周喆. 水质条件对外来入侵生物水葫芦生长的影响[D]. 福州:福建农林大学,2008.
ZHOU Zhe. Effect of water quality on the growth of water hyacinth (*Eichhorniacrassipes* (Mart.) *Solms.*)[D]. Fuzhou: Fujian Agriculture and Forestry University, 2008. (in Chinese)
[40] 张浩. 集约化海水养殖废水多介质土壤滤层(MSL)与人工湿地技术处理效能的对比研究[D]. 杭州:浙江大学,2013.
ZHANG Hao. The comparative study of the performance between multi-soil-layering technology (MSL) and artificial wetland technology on treating concentrate aquaculture wastewater[D]. Hangzhou: Zhejiang University, 2013. (in Chinese)
[41] 钱志鸿,王义君. 面向物联网的无线传感器网络综述[J]. 电子与信息学报,2013,35(1):215-227.
QIAN Zhihong, WANG Yijun. Internet of things-oriented wireless sensor networks review[J]. Journal of Electronics & Information Technology, 2013, 35(1): 215-227. (in Chinese)
[42] LIU Y, HE Y, LI M, et al. Does wireless sensor network scale? A measurement study on GreenOrbs[J]. IEEE Transactions on Parallel and Distributed Systems, 2012, 24(10): 1983-1993.
[43] HE T, KRISHNAMURTHY S, LUO L, et al. VigilNet: an integrated sensor network system for energy-efficient surveillance [J]. ACM Transactions on Sensor Networks (TOSN), 2006, 2(1): 1-38.