

基于 G-RepVGG 和鱼类运动行为的水质监测方法

孙龙清^{1,2} 王泊宁^{1,2} 王嘉煜^{1,2} 王新龙^{1,2}

(1. 中国农业大学信息与电气工程学院, 北京 100083;

2. 农业农村部国家数字渔业创新中心, 北京 100083)

摘要: 水质恶化会直接造成水产养殖产量下降,严重时会导致水产动物大量死亡,给养殖企业造成严重经济损失。因此对水产养殖中水质参数进行实时监测具有重要意义。本文以斑石鲷为研究对象,提出了一种基于鱼类行为的水质监测方法。该方法通过摄像机拍摄到的图像数据就可以非侵入地完成水质参数的实时监测,避免了安装复杂设备、对鱼类行为进行量化等繁琐过程。为了增加推理速度和降低模型参数量,通过将 RepVGG block 与 GhostNet 相结合构建了 G-RepVGG 模型,使该模型更适用于移动设备的部署。提出了计算量较少、推理速度快、更适合水质快速监测的 Cheap Ghost 操作和计算量大、精确率高、更适合水质的精确监测 Expensive Ghost 操作。由于多分支网络适合进行训练但是在推理速度上低于单分支网络,因此通过模型重参数化首先将卷积层以及批归一化(Batch normalization, BN)层合并,随后再将3路卷积合并为1路,大大降低模型参数量、提高了模型推理速度,使模型更加适用于移动设备的推理。结果表明:使用 Cheap Ghost 操作的 G-RepVGG 在测试集中准确率达到 96.21%,图像处理速度达到 442.27 f/s,使用 Expensive Ghost 操作的 G-RepVGG 模型在测试集中准确率达到 97.63%,图像处理速度达到 349.42 f/s,从而在保证较高精度的前提下依旧具有较高的推理速度,在多个数据集中测试具有较好的鲁棒性。

关键词: 斑石鲷; 运动行为; 水质监测; 深度学习; 卷积神经网络

中图分类号: TP391 **文献标识码:** A **文章编号:** 1000-1298(2022)S2-0210-09

Water Quality Monitoring Based on Fish Movement Behavior and G-RepVGG

SUN Longqing^{1,2} WANG Boning^{1,2} WANG Jiayu^{1,2} WANG Xinlong^{1,2}

(1. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China

2. National Digital Fisheries Innovation Center, Ministry of Agriculture and Rural Affairs, Beijing 100083, China)

Abstract: Water in aquaculture is a necessary place for aquatic animals to survive and live. The deterioration of water quality will directly lead to the decline of aquaculture production, and in severe cases, it will lead to the death of a large number of aquatic organisms and cause serious economic losses to aquaculture enterprises. Therefore, the real-time monitoring of water quality parameters in aquaculture is of great significance. A method for water quality monitoring based on fish behavior was proposed with *Oplegnathus punctatus* as research object. The method can non-invasively complete the real-time monitoring of water quality parameters through the image data captured by the camera, avoiding the tedious installation of complex equipment and the quantification of fish behavior. To increase the inference speed and reduce the amount of model parameters, this method combined RepVGG block with GhostNet. Aiming at the problems of rapid water quality monitoring and accurate water quality monitoring, the Cheap Ghost operation and the Expensive Ghost operation were proposed. Finally, the three branches were merged through model reparameterization, which greatly reduced the amount of model parameters and improved the model inference speed. The results showed that the G-RepVGG operated by Cheap Ghost achieved an accuracy of 96.21% in the test set and can infer 442.27 images per second. The G-RepVGG model operated with Expensive Ghost achieved 97.63% accuracy in the test set and can infer 349.42 images per second. Therefore, it still had a high inference speed under the premise of ensuring

收稿日期: 2022-06-21 修回日期: 2022-08-16

基金项目: 国家重点研发计划项目(2020YFD0900201)

作者简介: 孙龙清(1964—),男,副教授,主要从事农业信息化及农业物联网技术研究,E-mail: sunl_q@163.com

high accuracy, and had better robustness in testing in multiple data sets. The research result can quickly and accurately monitor water quality, detect water quality deterioration in time, and reduce losses caused by water quality deterioration, providing ideas and methods for water quality monitoring.

Key words: *Oplegnathus punctatus*; motor behavior; water quality monitoring; deep learning; convolutional neural network

0 引言

水产养殖中水质是影响鱼类生长发育的重要因素^[1-3]。现有比较常见的水质监测方法为理化分析法,虽然具有很强的针对性,能够对水体中各种需要检测的危害物质给出科学、准确可靠的依据^[4],但分析化验过程需要较长的时间,难以实现实时监测,并且无法直观反映水体中各种水质参数的综合情况^[5]。水是鱼类赖以生存的环境,因此通过鱼类行为分析对当前水环境进行监测显得至关重要。

国内外已有许多学者以鱼为指示生物,通过鱼类行为量化实现水质监测。在该类研究中对鱼类行为进行量化分析是解决生物式水质监测^[5-7]、水产养殖系统智能化^[8-9]和生产优化^[10-12]等多方面研究问题的基础。LI 等^[13]利用隐马尔可夫模型分析了在化学污染下斑马鱼的行为变化规律。LIU 等^[14]提取了斑马鱼的速度、平均速度等运动参数以研究经甲醛处理后的行为变化。LIAO 等^[15]利用支持向量机^[16-17] (Support vector machine, SVM) 对量化得到的鱼群分散度和平均游泳速度进行行为分析实现对水质的评价。基于机器学习方法的量化分析获得了较好的效果,广泛应用于各种行为中。

然而以上通过鱼类行为量化实现水质监测存在一些不足,首先在上述研究中行为量化是分析鱼类行为最基础也是最重要的一个步骤^[18-20]。其量化精度直接决定模型最终的精度。由于目前绝大多数运动参数的提取算法都是以多目标跟踪为前提,跟踪精度会直接影响运动参数提取的结果,但在真实的养殖环境当中鱼类的高密度、较差的照明情况以及较大的噪声将大大加大多目标跟踪的难度,最终导致模型精度的下降。并且,由于量化特征都是手动选取的,利用这些特征来对水质参数进行监测的适用性往往较低,很难确定最优解。简单的直方图或特征融合往往忽略了图像本身的相对空间信息;因此,这种方法有很多局限性^[21]。与上述方法相比,深度学习模型利用数据直接进行特征和表达关系的自学习,更能提取代表性特征^[22]。YANG 等^[23]将鱼类行为分为摄食前行为、惊吓行为、开始摄食、摄食行为和摄食后 5 类并通过 DAN-EfficientNet-B2 进行分析,准确率达到 89.56%;

WANG 等^[24]将鱼类行为分为摄食行为、低温行为、惊吓行为、缺氧行为以及正常行为,通过双流三维卷积神经网络进行分类,准确率达到了 95.79%。以上研究均没有对鱼类行为参数进行量化,将图像数据直接输入网络,实现了鱼类行为分析。

基于此,本研究通过分析在不同温度以及溶解氧下的摄食行为,实现对鱼类所处的溶解氧浓度以及温度的监测。本文主要研究内容包括:首先针对真实水产养殖环境下鱼类密集难以进行行为量化以及量化指标选择盲目性的问题,采用一种非量化的鱼类行为分析方法。其次针对鱼类行为划分粒度较粗的问题,继续细化粒度,将鱼类所处的环境按照溶解氧浓度以及温度进行更细粒度的划分。最后将 RepVGG^[25]与 GhostNet^[26]相结合,提出一种轻量化的基于鱼类行为的水质参数分析模型 G-RepVGG。

1 材料与方法

1.1 数据获取

数据取自国家数字渔业创新中心实验基地,实验对象为斑石鲷。养殖池直径为 3.2 m,高度为 0.6 m。为了方便排出鱼类的排泄物,中间放置一直径 0.5 m 的圆筒。传感器布置在水池一侧,摄像机布置在离水池高 1.55 m 的一侧,摄像机底部距离池壁 0.7 m,以 25 f/s 录制视频,摄像机布置如图 1 所示。养殖池中斑石鲷共 50 尾,平均质量 58 g,实验开始前提前在该养殖池中饲养 7 d,以适应养殖池环境。



图 1 实验平台

Fig. 1 Experimental platform

实验控制的水质参数为温度以及溶解氧浓度,控制温度在 17 ~ 30℃ 之间,溶解氧浓度为 3.5 ~ 8.0 mg/L。pH 值、氨氮含量、亚硝酸盐含量等水质参数均保持不变。在水质参数变化过程中,通过传感器记录当前水质参数,并通过摄像机同步录制当

前鱼类的行为,并将当前鱼类行为与水质参数相对应。鱼类投喂时间为 07:30 以及 16:30,投喂量为 30 g,在投喂前打开摄像机开始视频数据的采集并记录当前溶解氧浓度变化。

1.2 图像预处理

在投喂过程中共获取到了 12 个鱼类摄食行为视频片段,每个视频片段时长为 854 s。使用 Python 代码对视频数据进行处理,每 50 帧截取 1 幅图像并修改尺寸为 64 像素 × 64 像素,划分为训练集、测试集。根据当前水环境当中溶解氧浓度以及温度对图像进行类别划分,由于溶解氧含量低于 5.0 mg/L 时会对鱼体生长产生不利影响^[27],因此将溶解氧浓度高于 5.0 mg/L 划分为常氧,溶解氧浓度低于 5.0 mg/L 划分为低氧,正常的斑石鲷养殖温度为 22 ~ 23℃,水温高于 25℃ 时鱼类易患寄生虫病,水温低于 20℃ 时也不利于鱼类的正常生长,因此,将水温低于 20℃ 划分为低温,水温 20 ~ 25℃ 划分为常温,水温高于 25℃ 划分为高温。基于此,将数据集划分为低温低氧(144 幅)、低温常氧(171 幅)、常温低氧(171 幅)、常温常氧(210 幅)、高温低氧(150 幅)、高温常氧(214 幅)6 类。数据集总共包含 1 060 幅图像,638 幅图像用于训练,422 幅图像用于测试。每类鱼类行为数据集如图 2 所示。

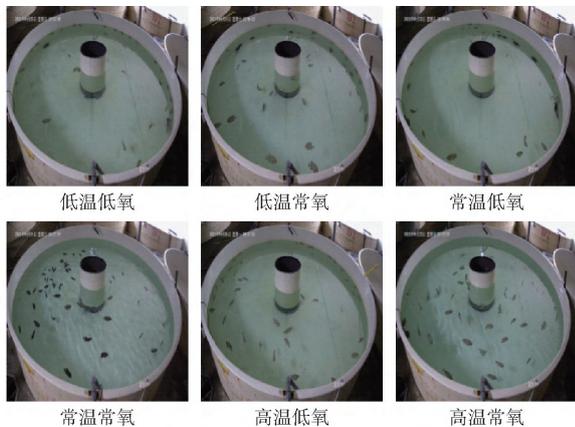


图 2 鱼类行为数据集

Fig. 2 Fish behavior dataset

2 基于鱼类行为的水质监测方法

2.1 整体网络结构

本文提出的网络结构如图 3 所示。在 G-RepVGG 模型中,输入图像首先通过一个 RepVGG blocks 进行降维,将输入图像尺寸由 $W \times H \times 3$ 降维到 $\frac{W}{2} \times \frac{H}{2} \times C$,在本文中 C 取 64。随后依次通过阶段 1~4,在每个阶段中首先将图像的高宽降低为上一阶段的一半,通道数升高到上一阶段的两倍。由于单纯使用 RepVGG blocks 会增加模型计算量,单

纯使用 G-RepVGG blocks 会造成模型精确率下降,因此在每一个阶段中都由相邻的 RepVGG blocks 以及 G-RepVGG blocks 堆叠组成。通过将 RepVGG block 与 G-RepVGG block 堆叠既保证推理速度又保证了较低的计算量。同时参考 Swim Transformer^[28]将每个阶段 blocks 数量设为 1:1:3:1,与原模型相比达到了更好的效果。

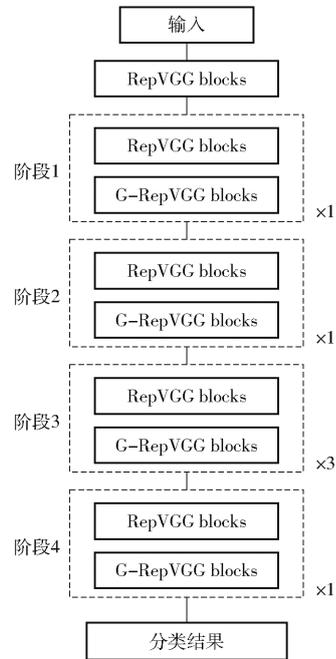


图 3 整体网络结构图

Fig. 3 Overall network structure diagram

2.2 RepVGG block

传统的单路卷积神经网络在性能上往往无法取得令人满意的效果。由于梯度爆炸以及梯度消失等现象导致在训练中往往难以获得较高的准确率。在以 ResNet 为代表的多路卷积神经网络中创立一个捷径分支使得网络输出为 $y = f(x) + x$ 。当输入维度与输出维度不相等时,使用卷积核尺寸为 1×1 的卷积对结晶分支维度进行调整,网络输出变为 $y = f(x) + g(x)$, g 表示卷积核尺寸为 1×1 的卷积操作。通过捷径分支可以将网络看作多个较浅网络组成的隐式集合^[29],因此一定程度减少由于梯度消失、梯度爆炸等现象造成的网络性能下降。多分支网络可以为网络输出提供更多的可能性,大大增加网络的表示能力从而提高网络性能。

但是多分支网络在推理过程中会大大增加内存消耗,如图 4 所示,在多分支中每一个分支的计算结果都需要保存在内存中,只有当多分支计算结果完成融合后内存消耗才会减少。因此多分支结构将造成内存消耗成倍增加,这将极大的提高移动端设备的硬件开销。图 4a、4b 为训练过程中的 RepVGG block,图 4c 为推理过程中的 RepVGG block,多分支

网络可以获得更好的训练效果,训练完成后不适合进行推理。因此在训练过程中采用 3 个分支的网络进行训练。

训练过程以及推理过程公式为

$$y_{\text{train}} = \begin{cases} f(x) + g(x) + x & (\text{步长为 } 1) \\ f(x) + g(x) & (\text{步长为 } 2) \end{cases} \quad (1)$$

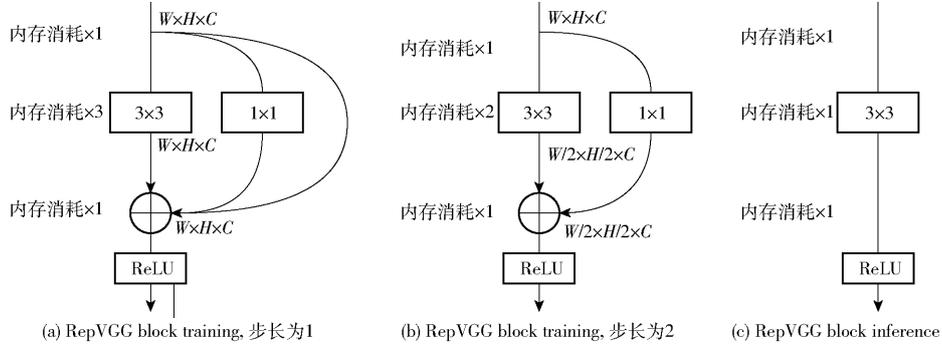


图 4 RepVGG 网络结构图

Fig. 4 RepVGG network structure diagrams

2.3 G-RepVGG block

在卷积神经网络当中同一层中不同卷积核所生成的特征图大都具有一定的相似性^[27]。考虑到 CNN 网络中特征图的广泛冗余,因此不需要采用繁重的计算生成大量相似的特征图,将 GhostNet 思想运用到 RepVGG blocks 中,构建 G-RepVGG block。首先通过普通卷积操作生成一定数量的特征图,随后通过一个简单的线性操作生成剩余部分的特征图。通过 Ghost 操作使得生成特征图总数不变的前提下,模型参数量以及计算量均有明显降低。为了防止模型性能的下降,在 G-RepVGG block 不通过 Ghost 操作生成过多特征图,综合模型性能以及模型计算量后选择先生成一半的特征图,随后通过 Ghost 操作生成另一半特征图。

训练过程中的 G-RepVGG block 如图 5a 所示,蓝色部分代表 Ghost 操作。在 G-RepVGG block 训练过程中首先分别通过一个卷积核为 3×3 的卷积以及卷积核为 1×1 的卷积将输入数据的维度由 2C 降为 C,由于输入数据维度与输出数据维度不相等,因此去掉捷径分支。为更好的生成高质量的特征图在 Ghost 操作中通过卷积核大小为 3×3 的卷积以及卷积核大小为 1×1 的卷积以及捷径分支使得网络更加易于训练,从而大大提升网络性能。由于在后续操作中均会对多个分支进行合并,因此 Ghost 操作中的多个卷积核均会被合并成一个卷积核为 3×3 的卷积,因此在此处采用多个分支生成特征图并不会增加网络计算量。

推理过程的 G-RepVGG block 如图 5b 所示。多分支结构虽然有利于取得较好的训练结果,但是

$$y_{\text{inference}} = f(x) \quad (2)$$

式中 $f(x)$ ——3×3 卷积操作

由于现有的硬件条件对 3×3 的卷积有着更高的效率^[26],因此将训练后的多分支网络均重参数化为仅包含 3×3 卷积的单分支网络,从而在不影响模型性能的前提下大大提高推理效率。

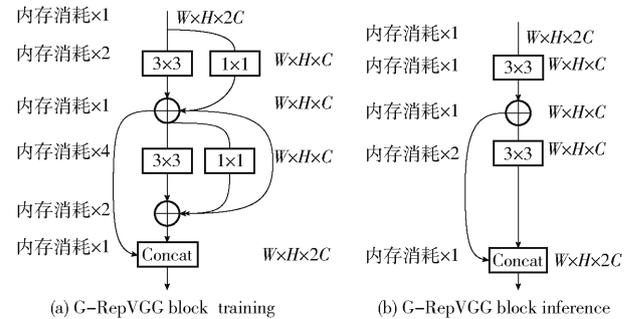


图 5 G-RepVGG block 网络结构图

Fig. 5 G-RepVGG block network structure diagrams

会大大拖慢推理速度增大内存开销。因此采用 RepVGG 的思路在推理过程中将多分支网络合并成仅使用卷积核尺寸为 3×3 的卷积操作的单分支网络,经过合并后 G-RepVGG block 由复杂的多分支网络变为仅包含两个卷积核尺寸为 3×3 的卷积操作的单分支网络,从而大大增加推理速度,减少内存开销,使得网络更适用于移动设备的部署。

2.4 Ghost 操作

在 G-RepVGG 当中可以选择使用两种 Ghost 操作: Cheap Ghost 操作或者 Expensive Ghost 操作,二者操作如图 6 所示。在 Cheap Ghost 操作中生成的蓝色特征图与原红色特征图为一一对应的关系,直接对原特征图进行一个简单的线性操作即可生成新的特征图,在 Expensive Ghost 操作中生成的每一个蓝色特征图包含所有红色特征图的信息,在新特征图的生成过程中对多幅原特征图进行融合,随后对其进行线性操作得到新的特征图。二者计算公式为

$$y_{\text{cheap}}^i = x^i * f + b \quad (3)$$

$$y^i_{\text{expensive}} = [x^1 \ x^2 \ \dots \ x^n] * f + b \quad (4)$$

式中 y^i ——生成的第 i 幅特征图
 x^i ——原有的第 i 幅特征图
 $*$ ——卷积操作
 b ——线性操作参数
 n ——原特征图的数量

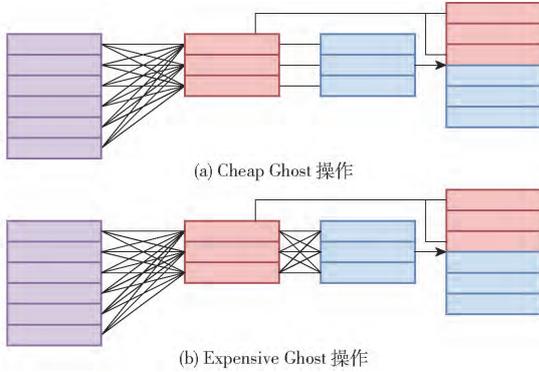


图6 Cheap Ghost 操作以及 Expensive Ghost 操作
 Fig.6 Cheap Ghost operation and Expensive Ghost operation

线性操作参数通过训练得到。Cheap Ghost 操作由于生成的特征图与原特征图为一一对应关系,直接对原特征图进行线性操作生成新的特征图,因此计算量较少,可以简单快捷的生成大量特征图,但是由于仅仅通过线性变换得到特征图,通过 Ghost 操作生成的特征图与原特征图相似度过高,将造成模型性能下降。在 Expensive Ghost 操作中首先将原有特征图进行融合,随后再进行线性变换生成新的特征图。Expensive Ghost 使得生成的特征图均融合所有原特征图信息,因此计算量较大,但生成的特征图质量较高,模型性能优于 Cheap Ghost 操作。与 Cheap Ghost 操作相比 Expensive Ghost 操作一定程度上可以看作增加了网络层数,从而提升了模型效果。

2.5 重参数化

为了提高训练后模型的推理速度,对训练后的模型进行重参数化,将其重参数化为仅包含卷积核为 3×3 卷积操作的网络。在网络训练中,每一个卷积操作后都跟随着一个 BN 操作。首先将卷积层与 BN 层合并,随后将每个分支卷积核大小转化为 3×3 ,最后将多路分支合并为一路。合并操作如图 7 所示。

卷积层与 BN 层的合并:没有偏置的卷积操作公式为

$$\text{Conv}(x) = W(x) \quad (5)$$

式中 W ——卷积核

BN 层操作可记为

$$\text{BN}(x) = \gamma \frac{x - \mu}{\sigma} + \beta \quad (6)$$

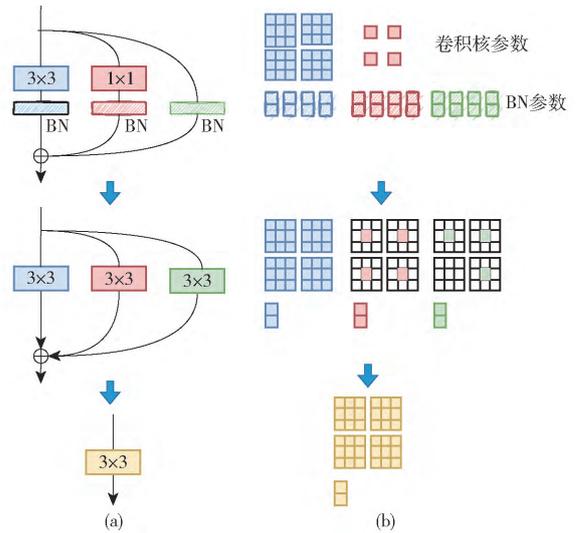


图7 模型重参数化过程图

Fig.7 Model reparameterization process diagram

式中 μ ——均值 σ ——标准差

γ, β ——可学习的倍率、偏差

卷积操作与 BN 操作结合后公式为

$$\text{BN}(\text{Conv}(x)) = \gamma \frac{W(x) - \mu}{\sigma} + \beta = \frac{\gamma W(x)}{\sigma} + \beta - \frac{\gamma \mu}{\sigma} \quad (7)$$

二者结合后可以看作一个简单的卷积操作,卷积核 W 以及偏置 b 分别为

$$\begin{cases} W = \frac{\gamma W}{\sigma} \\ b = \beta - \frac{\gamma \mu}{\sigma} \end{cases} \quad (8)$$

卷积核尺寸调整:通过卷积核尺寸调整将卷积核大小都调整为 3×3 。具体操作如图 7b 所示,白色方格代表卷积核中为 0 的元素。对大小为 1×1 的卷积核,从外围填充一圈 0 元素,从而将卷积核大小变为 3×3 。对于捷径分支由于其原本不存在卷积操作,因此需要人为构建一个 3×3 的卷积核使得输入数据经过该卷积核处理后输出不发生改变。构建方法为首先生成一个 $n \times n$ 的单位矩阵, n 为输入输出的通道数,随后将每一行看作为一个 1×1 大小的卷积核,最后将这个 1×1 的卷积核填充为 3×3 ,从而完成捷径分支的卷积核构建。捷径分支生成的卷积核如图 7b 所示,卷积核绿色部分值为 1,白色部分值为 0,使得输入数据在经过该卷积核处理后数据不发生变化。

多分支合并:在经过卷积层与 BN 层合并以及卷积核尺寸调整后,对 3 路分支进行合并,将其合并成为 1 路,从而大大增加推理速度。由于原多分支输出结果为输入数据分别经过 3 条分支后简单的相加,因此将经过处理后生成的 3 个 3×3 大小的卷积

核的权重以及偏置直接相加,从而保证合并后单分支输出与原多分支输出相同,在不改变模型输出的前提下大大提高了推理效率。

3 实验结果与分析

3.1 参数设定

模型训练和测试均在同一台计算机进行,CPU 为 AMD Ryzen 7 5800H, GPU 为 NVIDIA GeForce RTX 3070,使用 Pytorch1.6.0 作为深度学习框架, CUDA 10.2, CUDNN7.5.6, Windows 10 操作系统,运行内存 16 GB。

为了进一步提高网络运行效率,将输入图像尺寸设定为 64 像素 × 64 像素。使用 Adam 优化器进行优化,学习率设置为 0.000 1,损失函数使用交叉熵损失,训练持续 40 个迭代周期,批尺寸设置为 10。

3.2 Ghost 操作

将 Cheap Ghost 操作与 Expensive Ghost 操作的 G-RepVGG 模型与原 RepVGG 模型进行比较。模型比较结果如表 1 所示,表中结果均为完成多路融合后的运行结果。

表 1 不同 Ghost 操作之间的性能对比

Tab.1 Comparison between different Ghost operations

模型	准确率/ %	参数量/ MB	浮点数运 算次数	图像处理速 度/(f·s ⁻¹)
RepVGG	95.00	21.25	1.57 × 10 ⁷	457.97
Cheap Ghost	96.21	18.99	1.33 × 10 ⁷	442.27
Expensive Ghost	97.63	23.15	1.59 × 10 ⁷	349.42

从表 1 可以看出,两种 Ghost 操作均提高模型精确率,与 RepVGG 模型相比,使用 Cheap Ghost 操作以及使用 Expensive Ghost 操作的精确率分别上升 1.21、2.63 个百分点。但是使用 Cheap Ghost 操作后网络参数量以及计算量均有一定程度的下降,在不降低网络性能的前提下使得网络更加轻量化。Expensive Ghost 操作虽然在精确率方面有着较大提高,但是在参数量以及计算量方面均有所提高,推理速度也显著降低。绘制二者的训练损失曲线如图 8 所示。从图 8 可以看出,Expensive Ghost 操作在 40 个迭代周期训练时损失值低于 Cheap Ghost 操作,可以更好地拟合训练数据从而达到更高的模型精度。

相比较而言 Cheap Ghost 操作更适用于快速水质监测,更适合移动端的部署。Expensive Ghost 操作由于精确率较高,因此更适用于水质的精确监测。

3.3 消融实验

在 G-RepVGG block 中新的特征图通过一个卷积核为 3 × 3 的卷积操作、卷积核为 1 × 1 的卷积操作以及捷径分支共同生成,为了验证 3 个分支存

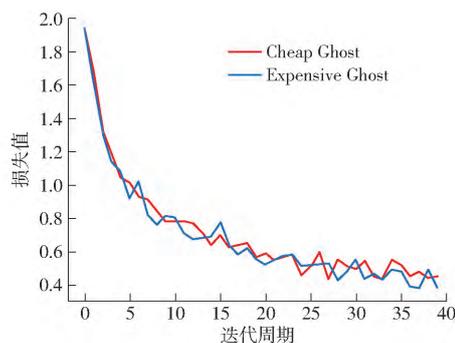


图 8 Expensive Ghost 操作、Cheap Ghost 操作训练损失值变化曲线

Fig. 8 Expensive Ghost operation and Cheap Ghost operation training loss diagram

在的必要性,逐一去掉了 3 个分支,实验结果如表 2 所示。

表 2 G-RepVGG block 消融实验结果

Tab.2 G-RepVGG block ablation experiment

3 × 3	1 × 1	Identity	准确 率/%	参数量/ MB	浮点数运 算次数	图像处理速 度/(f·s ⁻¹)
	✓	✓	94.08	18.99	1.33 × 10 ⁹	448.80
✓		✓	95.26	18.99	1.33 × 10 ⁹	436.03
✓	✓		95.97	18.99	1.33 × 10 ⁹	445.34
✓	✓	✓	96.21	18.99	1.33 × 10 ⁹	442.27

注:✓表示在模块中使用相应分支。

从表 2 中可以看出,由于训练完成后会进行融合操作将多分支融合为单一分支,因此在去掉任何一分支后模型参数量、计算量以及推理速度均未发生变化。但是在去掉任意分支后模型精确率均有一定程度的下降,在去掉 3 × 3 卷积后,由于无法融合像素点周围信息,精确率下降最为明显,在去掉 1 × 1 卷积后,由于缺少融合深度信息的能力,一定程度上造成了精确率的下降,在去掉捷径分支后,由于梯度爆炸以及梯度消失的问题导致精确率轻微下降。训练损失曲线如图 9 所示,通过 40 个迭代周期的训练,不去掉任何分支的 G-RepVGG 模型表现最优。

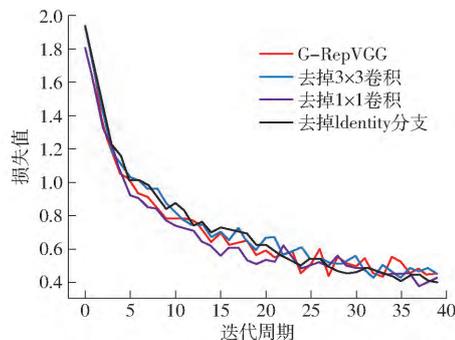


图 9 消融实验训练损失值变化曲线

Fig. 9 Training loss diagram of ablation experiment

由于在 G-RepVGG block 当中添加了多个分

支,并可以在不增加模型参数量以及计算量的前提下提升模型准确率,因此在 G - RepVGG block 中存在的 3 个分支均必不可少。

3.4 不同模型性能比较

为验证模型的有效性,保证对比实验的科学严谨,在相同软硬件环境以及训练参数的环境下将本文模型与 MobileNet V3 small^[30]、ResNet34^[29]、ResNet18^[29]、VGG16^[31] 进行对比,实验结果如表 3 所示,将采用 Cheap Ghost 操作的 G - RepVGG 称为 G - RepVGG cheap,将采用 Expensive Ghost 操作的 G - RepVGG 称为 G - RepVGG expensive。

表 3 不同模型对比实验结果

Tab.3 Comparing experiments of different models

模型	准确率/ %	参数量/ MB	浮点数运 算次数	图像处理速 度/(f·s ⁻¹)
VGG16	93.60	134.28	1.37 × 10 ⁸	300.41
ResNet18	94.31	11.17	1.48 × 10 ⁷	425.69
ResNet34	95.02	21.28	2.99 × 10 ⁷	215.76
MobileNet V3 small	93.60	1.52	5.70 × 10 ⁵	214.60
RepVGG	95.00	21.25	1.57 × 10 ⁷	457.97
G - RepVGG cheap	96.21	18.99	1.33 × 10 ⁷	442.27
G - RepVGG expensive	97.63	23.15	1.59 × 10 ⁷	349.42

从表 3 可以看出,本文提出的 G - RepVGG 模型在准确率上最高。VGG16 模型准确率最低,原因

是单分支结构。ResNet18 模型参数量较少,但难以达到较高的准确率,且在计算量以及推理速度方面低于本文提出的 G - RepVGG cheap 模型。ResNet34 模型虽然在准确率上略高于 ResNet18 模型,与本文模型相对接近,但是在其他各方面均落后于本文模型。MobileNet V3 small 虽然在参数量以及计算量上远低于本文模型,但是由于 DW 卷积操作计算效率较低,在推理速度上远低于本文模型,仅与 ResNet34 模型相当。由此可见模型计算量不能完全代表模型推理速度,本文模型虽然计算量高于 MobileNet V3 small,但是由于本文模型广泛采用高效的 3 × 3 卷积,依旧可以取得较快的推理速度。同时从实验中可以看出,VGG16 模型在计算量方面为 ResNet34 模型的 3.4 倍,MobileNet V3 small 的 240 倍,但是由于其采用高效的 3 × 3 卷积,在推理速度方面依旧高于 ResNet34 以及 MobileNet V3 small。

G - RepVGG 模型与 RepVGG 模型的混淆矩阵如图 10 所示。从图 10 可以看出,高温低氧为难分类别,主要的分类错误均位于高温低氧的分类中,与 RepVGG 模型相比,G - RepVGG 模型在高温低氧的分类上准确率大幅度提升,尤其是 G - RepVGG expensive 通过 Expensive Ghost 操作使得准确率达到最高,大大提高了高温低氧的分类准确率。

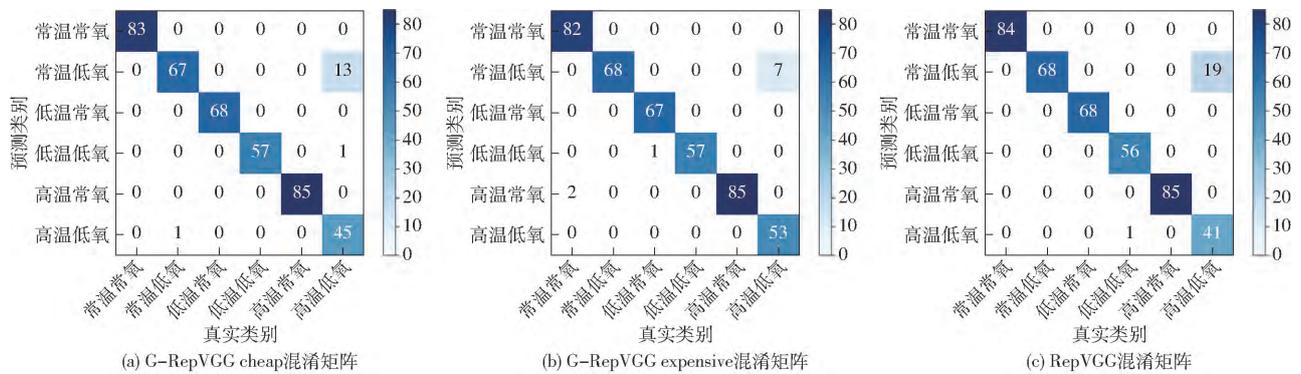


图 10 G - RepVGG cheap、G - RepVGG expensive 以及 RepVGG 混淆矩阵

Fig.10 G - RepVGG cheap, G - RepVGG expensive and RepVGG confusion matrix

综上所述,本文模型可以较好地平衡准确率、计算量以及推理速度三者之间的关系,将三者均保持在相对较优的范围中,更加适用于移动设备的部署。

4 讨论

通过实验可以看出模型计算量与模型推理速度并不是简单的线性关系,在同样的硬件条件下并不是计算量低的模型推理速度一定快,从实验中可以看出,MobileNet V3 small 模型虽然在计算量方面远低于本文模型,但是在推理速度方面远远慢于本文模型,G - RepVGG cheap 模型虽然在计算量上低于原始的 RepVGG 模型但是在推理速度方面依旧低于

传统 RepVGG 模型。存在这种现象的主要原因是 MobileNet V3 small 模型中大量采用复杂的 DW 卷积,本文的 Ghost 操作硬件适配度相对较低,而 RepVGG 模型中仅使用了硬件适配度最高的 3 × 3 卷积,使其在计算量较高的前提下具有较高的计算密度。

5 结论

(1) 基于鱼类行为的快速水质监测方法避免了复杂的量化过程,减少因鱼类行为量化不精确造成的误检。

(2) 基于 G - RepVGG 模型的快速精确水质监

测研究通过将 RepVGG 与 GhostNet 相结合在保证推理速度的基础上, 一定程度减少了模型参数量, 使模型更加适合移动端的部署。通过提出的 Cheap Ghost 操作及 Expensive Ghost 操作适应不同精度的监测需求。最终通过模型重参数化将多路分支合并

为仅包含 3×3 卷积的高效模型, 大大降低了模型参数量, 提高了模型推理速度。

(3) 基于 G-RepVGG 模型的识别准确率为 97.63%, 图像处理速度达到 442.27 f/s。

参 考 文 献

- [1] OPPEDAL F, DEMPSTER T, STIEN L H. Environmental drivers of Atlantic salmon behaviour in sea-cages; a review[J]. *Aquaculture*, 2011, 311(1-4): 1-18.
- [2] SEAGAR J, MILN E, IA N, et al. Effects of short-term oxygen depletion on fish[J]. *Environmental Toxicology & Chemistry*, 2000, 19(12): 2937-2942.
- [3] JESÚS C V, FRANCISCO-JAVIER M L, BENJAMÍN G G. Oxygen consumption and ventilatory frequency responses to gradual hypoxia in common dentex (*Dentex dentex*): basis for suitable oxygen level estimations[J]. *Aquaculture*, 2006, 256(1-4): 542-551.
- [4] YUAN F, HUANG Y F, CHEN X, et al. A biological sensor system using computer vision for water quality monitoring[J]. *IEEE Access*, 2018. DOI:10.1109/ACCESS.2018.2876336.
- [5] XIAO G, FENG M, CHENG Z B, et al. Water quality monitoring using abnormal tail-beat frequency of crucian carp[J]. *Ecotoxicology & Environmental Safety*, 2015, 111(1): 185-191.
- [6] 彭红梅. 基于生物水质监测的鱼体运动状态检测系统研究[D]. 西安: 西安邮电大学, 2017.
PENG Hongmei. Research on fish movement state detection system based on biological water quality monitoring[D]. Xi'an: Xi'an University of Posts and Telecommunications, 2017. (in Chinese)
- [7] 王丽娜. 基于动态图像理解的水质生物监测系统研究与应用[D]. 杭州: 电子科技大学, 2011.
WANG Li'na. Research and application of water quality biological monitoring system based on dynamic image understanding [D]. Hangzhou: University of Electronic Science and Technology, 2011. (in Chinese)
- [8] SUN M, HASSAN S G, LI D. Models for estimating feed intake in aquaculture: a review[J]. *Computers & Electronics in Agriculture*, 2016, 127(Complete): 425-438.
- [9] MARTINS C I M, GALHARDO L, NOBLE C, et al. Behavioural indicators of welfare in farmed fish[J]. *Fish Physiology and Biochemistry*, 2012, 38(1): 17-41.
- [10] 颜波, 石平. 基于物联网的水产养殖智能化监控系统[J]. *农业机械学报*, 2014, 45(1): 259-265.
YAN Bo, SHI Ping. Intelligent monitoring system for aquaculture based on Internet of things[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2014, 45(1): 259-265. (in Chinese)
- [11] YE Z, ZHAO J, HAN Z, et al. Behavioral characteristics and statistics-based imaging techniques in the assessment and optimization of Tilapia feeding in a recirculating aquaculture system[J]. *Transactions of the ASABE*, 2016, 59(1): 345-355.
- [12] 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]. *农业机械学报*, 2019, 50(12): 260-267.
SUN Longqing, LIU Ting, CHEN Shuaihua, et al. Research on multi-target fish object proposal detection algorithm[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(12): 260-267. (in Chinese)
- [13] LI Y, LEE J M, CHON T S, et al. Analysis of movement behavior of Zebrafish (*Danio rerio*) under chemical stress using hidden markov model[J]. *Modern Physics Letters B*, 2013, 27(2): 1350014.
- [14] LIU Y, LEES H, CHON T S, et al. Analysis of behavioral changes of zebrafish (*Danio rerio*) in response to formaldehyde using self-organizing map and a hidden Markov model[J]. *Ecological Modelling*, 2011, 222(14): 2191-2201.
- [15] LIAO Y, XU J Y, WANG W J. A method of water quality assessment based on biomonitoring and multiclass support vector machine[J]. *Procedia Environmental Sciences*, 2011, 10(part-PA): 451-457.
- [16] AVIDAN S. Support vector tracking[J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2004, 26(8): 1064-1072.
- [17] JOHNSON A E, HEBERT M. Using spin-image for efficient multiply model recognition in cluttered scenes[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1999, 21: 433-449.
- [18] PAPADAKIS V M, PAPADAKIS I E, LAMPRIANIDOU F, et al. A computer-vision system and methodology for the analysis of fish behavior[J]. *Aquacultural Engineering*, 2012, 46: 53-59.
- [19] HASLER C T, SUSKI C D, HANSON K C, et al. Effect of water temperature on laboratory swimming performance and natural activity levels of adult largemouth bass[J]. *Canadian Journal of Zoology*, 2009, 87(7): 589-596.
- [20] LEE C G, FARRELL A P, LOTTO A G, et al. The effect of temperature on swimming performance and oxygen consumption in adult sockeye (*Oncorhynchus nerka*) and coho (*O. kisutch*) salmon stocks[J]. *Journal of Experimental Biology*, 2003, 206(Pt 18): 3239-3251.
- [21] ZHOU C, XU D, CHEN L, et al. Evaluation of fish feeding intensity in aquaculture using a convolutional neural network and machine vision[J]. *Aquaculture*, 2019. DOI:10.1016/j.aquaculture.2019.04.056.

- [22] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436–444.
- [23] YANG L, YU H, CHENG Y, et al. A dual attention network based on efficientNet – B2 for short-term fish school feeding behavior analysis in aquaculture[J]. *Computers and Electronics in Agriculture*, 2021, 187:106316.
- [24] WANG G, MUHAMMAD A, LIU C, et al. Automatic recognition of fish behavior with a fusion of RGB and optical flow data based on deep learning[J]. *Animals*, 2021, 11(10): 2774.
- [25] DING X, ZHANG X, MA N, et al. RepVGG: making VGG-style convNets great again[C]//CVPR, 2021.
- [26] HAN K, WANG Y, XU C, et al. GhostNets on heterogeneous devices via cheap operations[J]. *International Journal of Computer Vision*, 2022, 130(4): 1050–1069.
- [27] HUANG J, LIU S, HASSAN S G, et al. A hybrid model for short-term dissolved oxygen content prediction[J]. *Computers and Electronics in Agriculture*, 2021, 186: 106216.
- [28] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[J]. arXiv:2103.14030.
- [29] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [30] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3[C]//Proceedings of the IEEE/CVF International Conference on Vision, 2019:1314–1324.
- [31] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv: 1409.1556, 2014.

~~~~~

(上接第74页)

- [8] WANG C, XING L, PENG R, et al. Competing failure analysis in phased-mission systems with multiple functional dependence groups[J]. *Reliability Engineering and System Safety*, 2017, 164(8): 24–33.
- [9] 孙尧, 孙志礼, 周杰, 等. 多状态多阶段任务系统的可靠度理论计算方法[J]. *东北大学学报(自然科学版)*, 2022, 43(5): 689–695.  
SUN Yao, SUN Zhili, ZHOU Jie, et al. Theoretical calculation method of reliability for multi-state phased-mission systems[J]. *Journal of Northeastern University (Natural Science)*, 2022, 43(5): 689–695. (in Chinese)
- [10] ZHAI Q, XING L, PENG R, et al. Aggregated combinatorial reliability model for non-repairable parallel phased-mission systems[J]. *Reliability Engineering and System Safety*, 2018, 176(8): 242–250.
- [11] MO Y, XING L, AMARI S V. A multiple-valued decision diagram based method for efficient reliability analysis of non-repairable phased-mission systems[J]. *IEEE Transactions on Reliability*, 2014, 63(1): 320–330.
- [12] LI X, LI Y, HUANG H, et al. Reliability assessment of phased-mission systems under random shocks[J]. *Reliability Engineering and System Safety*, 2018, 180(12): 352–361.
- [13] MO Y, XING L, ZHONG F, et al. Reliability evaluation of network systems with dependent propagated failures using decision diagrams[J]. *IEEE Transactions on Dependable and Secure Computing*, 2015, 13(6): 672–683.
- [14] WANG C, XING L, PENG R, et al. Competing failure analysis in phased-mission systems with multiple functional dependence groups[J]. *Reliability Engineering and System Safety*, 2017, 164(8): 24–33.
- [15] LI X, HUANG H, LI Y. Reliability analysis of phased mission system with non-exponential and partially repairable components[J]. *Reliability Engineering and System Safety*, 2018, 175(3): 119–127.
- [16] XU Z, MO Y, LIU Y, et al. Reliability assessment of multi-state phased-mission systems by fusing observation data from multiple phases of operation[J]. *Mechanical Systems and Signal Processing*, 2019, 118(1): 603–622.
- [17] CHAABANE K, KHATAB A, DIALLO C, et al. Integrated imperfect multi-mission selective maintenance and repairpersons assignment problem[J]. *Reliability Engineering and System Safety*, 2020, 199(7): 106895.
- [18] JIANG T, LIU Y. Selective maintenance strategy for systems executing multiple consecutive missions with uncertainty[J]. *Reliability Engineering and System Safety*, 2020, 193(1): 106632.
- [19] DO P, VU H C, BARROS A, et al. Opportunistic maintenance based on multi-dependent components of manufacturing system[J]. *CIRP Annals—Manufacturing Technology*, 2016, 65(1): 401–404.
- [20] WANG H Z. A survey of maintenance policies of deteriorating systems[J]. *European Journal of Operational Research*, 2002, 139(3): 469–489.
- [21] DO P, VU H C, BARROS A, et al. Maintenance grouping for multi-component systems with availability constraints and limited maintenance teams[J]. *Reliability Engineering and System Safety*, 2015, 142(10): 56–67.
- [22] HAI C V, DO P, BARROS A, et al. Maintenance planning and dynamic grouping for multi-component systems with positive and negative economic dependencies[J]. *IMA Journal of Management Mathematics*, 2015, 23(2): 145–170.
- [23] GENG J, AZARIAN M, PECHT M. Opportunistic maintenance for multi-component systems considering structural dependence and economic dependence[J]. *System Engineering and Electronics*, 2015, 16(3): 493–501.