

# 轻量化卷积神经网络在船舶分类中的应用

王文亮, 杨晓迪\*, 张博雅, 马吉顺, 曾鹏, 韩鹏

中船(浙江)海洋科技有限公司, 浙江 舟山 316000

**摘要** 为权衡船舶分类模型的分类精度和模型大小,提出一种改进 GhostNet-50 的轻量化卷积神经网络 AGNet 对自制的船舶数据集进行分类。首先,提出一种融合非对称卷积的 Ghost 模块,用于提升 AGNet 卷积过程的特征提取能力;然后,结合瓶颈结构,设计一种非对称 Ghost 瓶颈模块,在维持模型表达能力的同时能进一步降低计算成本;最后,去除 GhostNet-50 中的一层  $1 \times 1$  卷积,以降低整体模型的参数冗余。实验通过分类精度、参数量、计算量、推理速度等评价指标对所提方法进行多角度对比。实验结果中,AGNet 模型在 33 个类别的测试集中精度达到了 93.87%,模型参数量仅为  $0.72 \times 10^6$ ,相比 GhostNet-50 压缩了 46.67%,且精度提升了 2.93 个百分点。实验结果表明:AGNet 在较低模型大小的前提下能达到更优的分类效果,可较好应用到船舶分类任务中。

**关键词** 图像处理; 船舶分类; 轻量化; 卷积神经网络; 非对称卷积

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP213033

## Application of a Lightweight Convolutional Neural Network in Ship Classification

Wang Wenliang, Yang Xiaodi\*, Zhang Boya, Ma Jishun, Zeng Peng, Han Peng

CSSC (Zhejiang) Ocean Technology Co., Ltd., Zhoushan 316000, Zhejiang, China

**Abstract** A lightweight convolutional neural network, AGNet-improved GhostNet-50, is proposed for ship classification using self-made ship datasets while ensuring a desirable classification accuracy with a small model size. First, a Ghost module that integrates asymmetric convolution is proposed to improve the feature extraction capability of the AGNet convolution process. Next, combined with the bottleneck structure, an asymmetric Ghost bottleneck module is designed, further reducing the computational cost while maintaining the expression ability of the model. Finally, a  $1 \times 1$  convolution layer in GhostNet-50 is removed to reduce the parameter redundancy of the overall model. The proposed method was compared from multiple aspects using evaluation indexes such as classification accuracy, parameters, and computational and inference speeds. Based on the experimental results, the accuracy of the AGNet model in the test set of 33 categories reaches 93.87%, and the number of model parameters is only  $0.72 \times 10^6$ . Compared with GhostNet-50, the AGNet model is compressed in terms of size by 46.67%, and the accuracy is improved by 2.93 percentage points. The experimental results show that AGNet can achieve better classification performance with a smaller model size and can be better applied to ship classification tasks.

**Key words** image processing; ship classification; lightweight; convolutional neural network; asymmetric convolution

## 1 引言

随着深度学习在学术界大放异彩,尤其是在图像识别<sup>[1]</sup>、图像分割<sup>[2]</sup>、目标检测<sup>[3]</sup>等领域,以计算机视觉为基础的研究得到快速应用,如人脸识别<sup>[4-5]</sup>、光纤缺陷检测<sup>[6]</sup>、高光谱遥感图像分类<sup>[7]</sup>、船舶检测<sup>[8-9]</sup>等。当前,国内外局势复杂多变,在安防领域的研究逐渐成为

一个热点,尤其是对于港口、码头、海洋边境等区域中过往船舶的监控和识别。

在船舶检测和识别领域<sup>[10-11]</sup>,有船舶分类、船舶图像分割、船舶视频跟踪<sup>[12]</sup>等研究方向。有些学者致力于研究深度学习方法对船舶分类的应用<sup>[13]</sup>,如:任永梅等<sup>[14]</sup>为提高点云船舶图像的分类准确率,提出了一种基于三维卷积神经网络(3DCNN)的点云船舶图像分

收稿日期: 2021-11-23; 修回日期: 2021-12-20; 录用日期: 2022-01-17; 网络首发日期: 2022-01-27

基金项目: 辽宁省教育厅科学技术研究项目(LJ2020JCL023)

通信作者: \*1755018902@qq.com

类方法,所提方法达到了 96.14% 的分类准确率,但在现实场景中,大多数船舶数据以二维图像的形式存在,而三维点云船舶图像数据需要通过一些设备来获取,因此基于点云数据的船舶分类在应用方面存在一定的局限性;陈兴伟等<sup>[15]</sup>通过自制的船舶数据集,将船舶分为 5 个类别,分类精度超过了 90%,但收集的船舶图片有限,且仅能覆盖 5 个船型的分类任务。综上所述,关于船舶分类在实际应用方面的研究需要进一步深入。

在图像分类研究领域,为获取更好的分类精度,多数情况下需要设计更宽、更深的卷积神经网络(CNN)来提取更丰富的特征,如 ResNet、Inception<sup>[16-17]</sup>、EfficientNet<sup>[18]</sup>等网络模型,在公开数据集 ImageNet 上不断刷新更高的分类精度。但更宽、更深的网络导致训练的模型具有较大的参数量和运算量,使得在实际模型部署过程中需要占据较大内存空间,同时会损耗较多电量而耗费较大成本。为均衡网络模型参数量和模型分类精度,有些科研人员从特征提取的角度出发,设计了一系列的轻量化特征提取模块,在 ImageNet、CIFAR-10 数据集的分类上权衡分类模型的精度、存储空间和运算成本,起到了良好效果。如 MobileNet 系列<sup>[19-20]</sup>通过设计一种深度可分离卷积特征提取模块,相比传统卷积大幅降低了模型参数量和运算成本。肖振久等<sup>[21]</sup>为解决传统 CNN 全连接层的参数冗余性,在采用深度可分离卷积模块的基础上,提出一种利用克罗内克积(Kronecker product, KP)分解全连接层权重矩阵的方法,在维持分类模型精度的前提下达到了良好的压缩效果。非对称卷积网络(Asymmetric convolutional network, ACNet)<sup>[22]</sup>在传统对称卷积的基础上,设计了一种非对称卷积模块,在 ImageNet 分类任务中仅增加较低的运算成本便得到了更好的分类精度。GhostNet<sup>[23]</sup>在 MobileNetV3<sup>[24]</sup>的基础上,为解决特征图的冗余性,采用一种廉价的线性运算方法在更低的模型参数下,得到了更丰富的输出特征图,增强了特征提取的能力。

本文根据现有学者在船舶分类上所做的贡献和存在的一些问题,将重心放在军船分类的研究与应用方面。首先,从维基百科、百度百科等各大网络搜索平台上收集一系列的船舶图片并构建船舶数据集。然后提出一种改进的轻量化非对称重影网络(Asymmetric ghost network, AGNet)作为训练框架,通过对自制的船舶数据集进行训练和测试,最终得到 AGNet 分类模型,该模型具有参数量低、分类精度高特点,并能对现实场景中的 59 类军船图像进行识别,具有一定的理论和实际价值。

## 2 提出方法

首先,介绍轻量化 GhostNet 卷积模块的运算原理,分析该模块在特征提取过程中的参数量和运算量;然后,阐述 ACNet 中非对称卷积的特征提取过程,并

根据前两者的特点,提出一种结合非对称卷积的 Ghost 模块来提升分类模型的特征提取能力;最后,根据船舶数据集的特点,设计一种轻量化的 CNN 架构 AGNet。

### 2.1 GhostNet 卷积模块

GhostNet 是一种基于 MobileNet 系列的改进轻量化网络结构,该结构从特征图存在冗余性的问题出发,从可视化的特征图中发现了一些相似且冗余的特征。因此,提出一种轻量化的特征提取 Ghost 模块来得到丰富的输出特征图,Ghost 模块如图 1 所示。




图 1 Ghost 模块  
Fig. 1 Ghost module

图 1 中:Ghost 模块对输入特征图进行了一次传统卷积运算,该过程将原始的输入特征图  $X \in \mathbb{R}^{C \times H \times W}$  转化为  $Y' \in \mathbb{R}^{H' \times W' \times M}$ ,这里需满足  $M < C$  的条件,其思想是保证  $Y'$  的通道数小于  $X$ ,以此进行降维操作,该过程的计算量  $R_1$  和参数量  $F_1$  分别表示为

$$R_1 = C \times K \times K \times M \times H' \times W', \quad (1)$$

$$F_1 = C \times K \times K \times M. \quad (2)$$

经过上述步骤后,再将  $Y' \in \mathbb{R}^{H' \times W' \times M}$  分别进行一次恒等映射和  $M$  次线性操作。线性操作在图中分别用  $\Phi_1, \Phi_2, \Phi_M$  表示。其中, $M$  次线性操作将  $Y' \in \mathbb{R}^{H' \times W' \times M}$  进行通道分离,在每一个通道上,这种线性操作可以表示为卷积运算,每个线性操作的卷积核大小用  $d \times d$  表示,最终使每个通道的输出通道数为  $S-1$ 。 $M$  次线性操作所得的输出通道数为  $M(S-1)$ ,所需的计算量  $R_2$  和参数量  $F_2$  可表示为

$$R_2 = 1 \times d \times d \times (S-1) \times H' \times W' \times M, \quad (3)$$

$$F_2 = d \times d \times (S-1) \times M. \quad (4)$$

易知,一次恒等映射和  $M$  次线性操作将得到  $MS$  个输出通道,且满足:

$$MS = N, \quad (5)$$

式中: $N$  为 Ghost 模块的输出特征图,由于 Ghost 模块的输入、输出特征图 and 传统卷积结构相似,只需修改输入通道  $C$  和输出通道  $N$  的参数便可以通过即插即用方式将 Ghost 模块嵌入到其他 CNN 结构中。因此,作者在设计 GhostNet 架构时,借鉴了 ResNet 中的瓶颈模块结构,用设计的 Ghost 模块替换 ResNet 瓶颈模块

中的传统卷积层,得到 GhostNet 瓶颈模块, GhostNet 瓶颈模块结构如图 2 所示。

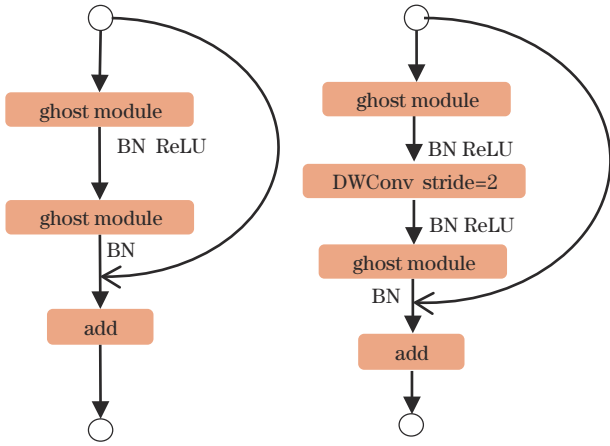


图 2 GhostNet 瓶颈模块。(a) 步长为 1 的瓶颈模块; (b) 步长为 2 的瓶颈模块

Fig. 2 Ghost bottleneck module. (a) Bottleneck module with a step size of 1; (b) bottleneck module with a step size of 2

图 2(a)中: GhostNet 残差模块将 ResNet 残差模块中的传统  $3 \times 3$  Conv 替换为 Ghost 模块,从而降低了 GhostNet 整体结构的参数量和运算量;在图 2(b)中: GhostNet 瓶颈模块同样将 ResNet 瓶颈模块中的传统卷积层替换为 Ghost 模块,同时将中间层原来的  $3 \times 3$  Conv 替换为步长为 2 的逐通道卷积,整个过程除进一步降低参数量外,还可用于特征图的下采样。

### 2.2 ACNet

ACNet 设计了一种非对称的特征提取模块。该方法通过通道复用方式,在同一特征图下分别采用不同类型的卷积核提取不同的信息,在增加较少训练参数量的同时提取到更丰富的特征,ACNet 模块的特征提取方式如图 3 所示。




图 3 ACNet 模块

Fig. 3 ACNet module

图 3 中: ACNet 模块将关注点放在如何强化卷积过程的特征提取,从而实现模型在性能上的提升。在卷积特征提取中,通常采用  $3 \times 3$  Conv 作为卷积的基础组件,同样,ACNet 模块中也是针对  $3 \times 3$  Conv 进行的,该方法将现有网络中的每一个  $3 \times 3$  Conv 替换成了一个由  $3 \times 3$  Conv、 $3 \times 1$  Conv 和  $1 \times 3$  Conv 组成的卷积模块,通过并行计算每一个卷积,最终将得到的输

出结果进行融合,经过激活函数 ReLU 后得到 ACNet 模块的输出。

### 2.3 非对称卷积的 GhostNet 模块

基于以上对 GhostNet 模块和 ACNet 非对称卷积模块的分析,为提升 Ghost 模块的特征提取能力,提出了一种非对称卷积的 Ghost 模块,如图 4 所示。




图 4 非对称 Ghost 模块

Fig. 4 Asymmetric Ghost module

图 4 中:非对称卷积的 Ghost 模块同样对输入特征图进行一次传统卷积运算用于通道降维,该过程的计算量  $R_1$  和参数量  $F_1$  如式(1)、式(2)所示。非对称卷积的 Ghost 模块采用非对称卷积运算的方式替换了之前的线性卷积运算,即非对称卷积的 Ghost 模块用  $X_1$ 、 $X_2$ 、 $X_M$  对 Ghost 模块中  $\Phi_1$ 、 $\Phi_2$ 、 $\Phi_M$  进行了替换,相比于式(3)、式(4),可计算出替换线性卷积部分的运算量  $R_3$  和参数量  $F_3$ ,表示为

$$R_3 = 1 \times (1 \times d + d \times d + d \times 1) \times (S - 1) \times H' \times W' \times M, \quad (6)$$

$$F_3 = (1 \times d + d \times d + d \times 1) \times (S - 1) \times M. \quad (7)$$

对比式(4)和式(7)可知,替换后的线性卷积层相比替换之前的参数量之比  $F_c$  为

$$F_c = F_3 / F_2 = (d^2 + 2d) / d^2 = 1 + 2/d. \quad (8)$$

当  $d=3$  时,  $F_c = 5/3$ ,参数量增加了 1.67 倍,同理,替换线性卷积之后的计算量同样增加了 1.67 倍。为分析非对称 Ghost 模块中非对称卷积和传统卷积的参数分布情况,通过式(2)和式(7),可得二者参数量之比  $F_d$  为

$$F_d = \frac{F_3}{F_1} = \frac{(1 \times d + d \times d + d \times 1) \times (S - 1) \times M}{C \times K \times K \times M} = \frac{(2d + d^2) \times (S - 1)}{C \times K \times K}. \quad (9)$$

当  $d=3$ ,  $K=1$ ,  $S=2$  时,  $F_d = 15/C$ ,由于输出通道数  $C$  通常大于 15,可知  $F_d < 1$ ,判断参数分布主要集中在传统卷积层。随着卷积层数的增加,输出通道数  $C$  会越来越大,  $F_d$  会越来越小,采用非对称卷积增加的一部分参数量所带来的影响将随着输出通道数  $C$  的增加而减弱。例如,当输入、输出通道数  $C$ 、 $N$  均为

80, 第一阶段传统卷积的输出通道数  $M$  为 40, 由式(2)和式(4)计算可得, Ghost 模块的参数量为 3560 个, 由式(2)和式(7)计算可得, 非对称 Ghost 模块的参数量为 3800 个, 参数增加量仅为 240 个。

构建非对称 Ghost 模块之后, 借鉴了 GhostNet 中的瓶颈模块结构, 以非对称 Ghost 模块为基础, 设计了两种不同形式的非对称 Ghost 瓶颈模块 (AG-bneck) 作为构建整体网络的基础结构, 设计的瓶颈模块如图 5 所示。

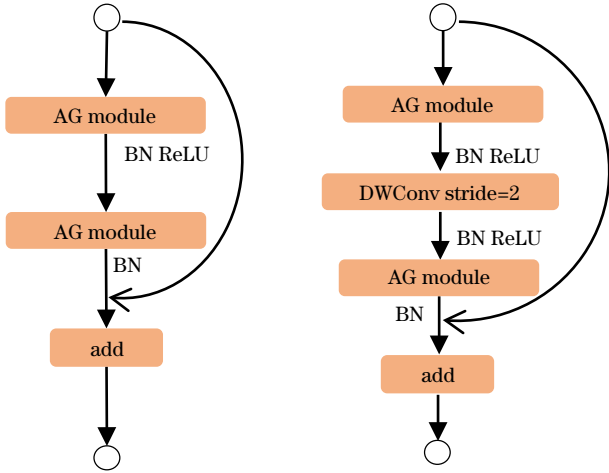


图 5 非对称 Ghost 瓶颈模块。(a) 步长为 1 的瓶颈模块;  
(b) 步长为 2 的瓶颈模块

Fig. 5 Asymmetric Ghost bottleneck module. (a) Bottleneck module with a step size of 1; (b) bottleneck module with a step size of 2

图 5(a) 为步长为 1 的瓶颈模块, 经过该模块后, 输出的特征图尺寸不变; 图 5(b) 为步长为 2 的瓶颈模块, 由于在中间层中将原来的  $3 \times 3$  Conv 替换为步长为 2 的逐通道卷积, 通过该模块后, 输出特征图的尺寸减半。

## 2.4 整体网络设计

为增强船舶数据集的特征提取能力并维持较低参数成本, 主要对 GhostNet-50 网络进行改进, 改进后的网络架构为 AGNet, AGNet 的具体参数如表 1 所示。

表 1 中: Input 列表示每一层操作的输入特征图, Operator 列表示各种操作类型, 其中, Conv 2d 为传统卷积操作; Conv 2d 后的  $3 \times 3$  和  $1 \times 1$  为传统卷积对应的卷积核尺寸; AG-bneck 为非对称 Ghost 瓶颈模块; AvgPool  $7 \times 7$  为步长为  $7 \times 7$  的全局平均池化。Exp 表示 Ghost 瓶颈模块内部的输出通道数, Out 表示每一层操作的最终输出通道数, SE 为 1 时表示该层操作将使用 Fire 模块<sup>[25]</sup>。Stride 表示该层操作的步长, 当步长为 2 时, 将进行特征图的下采样。相比 GhostNet-50, AGNet 首先将原来的 Ghost 瓶颈模块替换为非对称 Ghost 瓶颈模块用于增强分类模型的特征提取能力。为维持较低的参数量, 将 GhostNet-50 中的一层  $1 \times 1$  Conv 去除, 使得分类模型的整体参数量得到进

表 1 AGNet 的具体参数

Table 1 Detail parameters of AGNet

Input	Operator	Exp	Out	SE	Stride
$224^2 \times 3$	Conv 2d $3 \times 3$	-	8	-	2
$112^2 \times 8$	AG-bneck	8	8	-	1
$112^2 \times 8$	AG-bneck	24	12	-	2
$56^2 \times 12$	AG-bneck	36	12	-	1
$56^2 \times 12$	AG-bneck	36	20	1	2
$28^2 \times 20$	AG-bneck	60	20	1	1
$28^2 \times 20$	AG-bneck	120	40	-	2
$14^2 \times 40$	AG-bneck	100	40	-	1
$14^2 \times 40$	AG-bneck	92	40	-	1
$14^2 \times 40$	AG-bneck	92	40	-	1
$14^2 \times 40$	AG-bneck	240	56	1	1
$14^2 \times 56$	AG-bneck	336	56	1	1
$14^2 \times 56$	AG-bneck	336	80	1	2
$7^2 \times 80$	AG-bneck	480	80	-	1
$7^2 \times 80$	AG-bneck	480	80	1	1
$7^2 \times 80$	AG-bneck	480	80	-	1
$7^2 \times 80$	AG-bneck	480	80	1	1
$7^2 \times 80$	Conv 2d $1 \times 1$	-	480	-	1
$7^2 \times 480$	AvgPool $7 \times 7$	-	-	-	-
$1^2 \times 480$	FC	-	classes	-	-

一步缩减。此外, 由于 GhostNet-50 主要用于 ImageNet 公开数据集的分类任务, 分类类别数为 1000, 而本文的船舶数据集分别划分为 5 类、33 类、59 类, 因此将 FC 层的输出维度降低, 并在表中用 classes 表示输出维度。通过以上网络架构的改进, 最终得到轻量化的网络架构 AGNet。

## 3 实验方案与结果

### 3.1 环境配置及参数说明

实验在 Windows10 平台下采用 Pycharm 2020.2.2 作为训练船舶分类任务的开发平台, 采用 Anaconda 3.5.0 来配置 Python 虚拟环境, 版本为 Python 3.8。采用深度学习框架为 PyTorch 1.5.0, 并安装 Cuda 10.1 用于船舶分类训练和推理过程的加速。实验过程中, 还采用 Matplotlib 3.1.1 作为数据后处理的绘图工具。此外, 硬件环境主要有 Core (TM) i5-10400FCPU@2.90 GHz、GeForce GTX2060Mobile 显卡等。

为了便于对比, 训练过程中采用的初始学习率为 0.005, 并设置权重衰减系数为 0.0001, 批处理 (Batch size) 大小为 8, 采用 Adam 优化器训练 200 个迭代次数 (epoch), 并在 epoch 为 100 时将学习率减小为原来的  $1/10$ 。

### 3.2 数据集介绍

当前极少有关于军船图像相关的船舶数据集, 为实现相关分类任务, 在各大网站平台上收集了多种国

外的军舰图片。由于在实际收集过程中,有些船舶样本难于收集,造成每个类别的样本数量有较大差异,为克服样本数量的不均衡性,每个类别中筛选的船舶数量相当。在筛选过程中,分3次筛选并标注数据样本,除第一次外,每次均在前一次的基础上进行样本扩充。每次筛选获得的样本信息如表2所示。

表 2 样本集信息

Table 2 Information table of sample set

ID	Class	Train_set	Test_set
1	5	470	104
2	33	2938	636
3	59	4408	986

表 2 中:ID 表示筛选样本的次数;Class 表示每次筛选船舶图片后的样本类别数;Train\_set 和 Test\_set 分别表示每次筛选船舶图片后划分的训练集样本数和测试集样本数。

### 3.3 评价指标

参照大多数图像分类的评价指标方法,除了将图像分类精度作为核心参考指标外,还考虑分类模型的运算量、参数量、推理速度等评价指标。

分类精度  $P$  决定了分类模型的预测能力,精度越高,则分类模型的预测能力越强。 $P$  的计算公式为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (10)$$

式中: $N_{TP}$  为分类模型将图片正确预测为对应标签的个数; $N_{FP}$  为分类模型将图片错误预测为对应标签的个数。由于分类精度包含训练精度和测试精度,在图像分类任务中,测试精度更能真实反映分类模型的预测性能,因此在后续实验中主要分析的是测试精度,关于测试精度的描述均表示分类精度,二者可等同。

模型运算量通常用 FLOPs 表示,指浮点运算数。此外,还可以用乘加累积操作数(Multiply-accumulate operations, MACs)表示。二者均能表示神经网络的运算复杂度,通常情况下,MACs 为 FLOPs 的两倍。在后面的实验中,本文均选择 MACs 作为衡量模型复杂度的参考指标。

模型参数量表示模型的参数数量,包括卷积层中的参数、全连接层参数等。实验中的参数均采用 32 位浮点型数据,可以根据参数数量来衡量模型所占用的内存大小,即模型参数量越大占用的内存越大。

模型推理速度受多方面因素影响,综合反映了分类模型的整体运算效率,本实验将帧率作为衡量分类模型推理速度的快慢,单位为 frame/s,即每秒处理的船舶图片数越多,分类模型推理速度越快。

### 3.4 AGNet 有效性验证

为验证 AGNet 分类模型的有效性,列出了 4 个用于对比的网络结构,分别为 AGNet、GhostNet-50、AGNet-large 和 GhostNet-50-small,如图 6 所示。

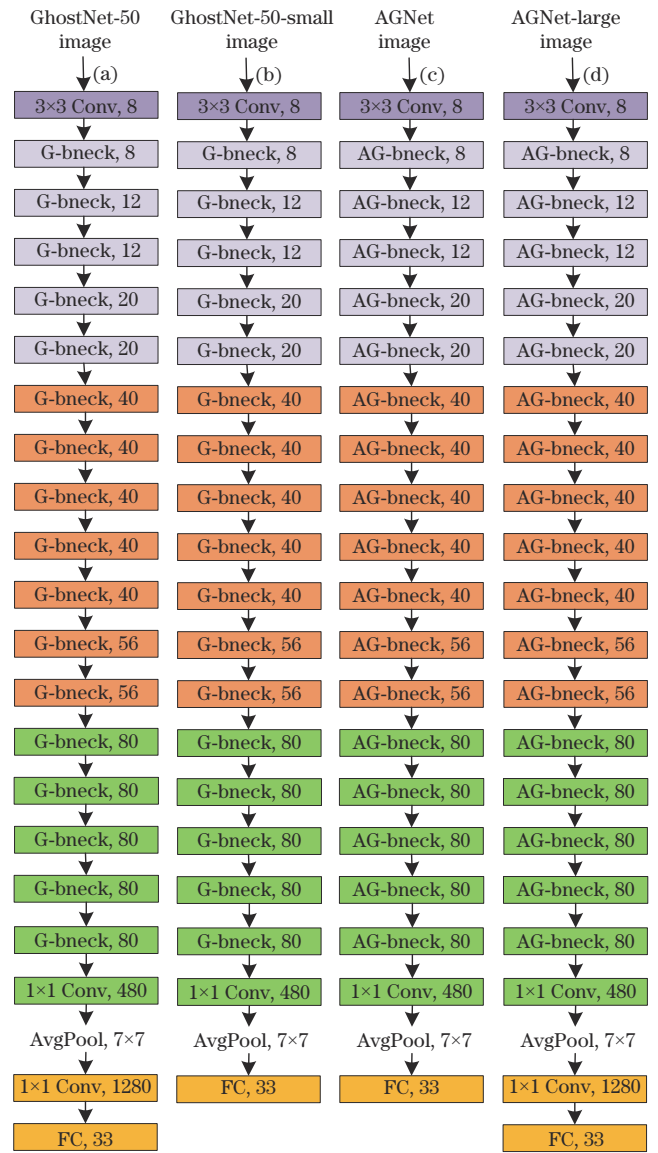


图 6 各网络整体结构对比

Fig. 6 Comparison of the overall structure of each network

图 6 中: GhostNet-50 为原始的网络结构, GhostNet-50-small 为去掉 GhostNet-50 中的一层  $1 \times 1$  Conv 组成的网络结构, AGNet 为改进后的网络结构, AGNet-large 为在 AGNet 的基础上增加了一层  $1 \times 1$  卷积组成的网络结构, G-bneck 表示 Ghost 瓶颈模块, AG-bneck 表示非对称 Ghost 瓶颈模块, AvgPool  $7 \times 7$  表示采用步长为  $7 \times 7$  的全局平均池化。每一层模块中后面的数字,均表示该模块的输出通道维度。

实验采用 33 个类别的船舶数据,分别对图 6 中的 4 个网络进行了训练和测试,表 3 列出了上述 4 个网络分别在运算量、参数量、测试精度、模型推理速度方面的对比情况,图 7、图 8 分别描述了二者在训练过程中的测试集精度和测试集损失曲线对比情况。

由表 3 可知, GhostNet-small-50 去掉  $1 \times 1$  Conv 之后,模型运算量相比 GhostNet-50 略有降低,但参数量相比 GhostNet-50 降低了 47.41%,且模型精度相比

表 3 各网络评价指标对比

Table 3 Comparison of each network evaluation indicators

Model	Multiply-accumulate operations / $10^6$	Parameters / $10^6$	Accuracy /%	Speed / (frame·s <sup>-1</sup> )
AGNet	49.35	0.72	93.87	47.76
AGNet-large	49.97	1.36	92.50	41.79
GhostNet-50	45.84	1.35	90.94	43.61
GhostNet-50-small	45.22	0.71	92.03	50.13

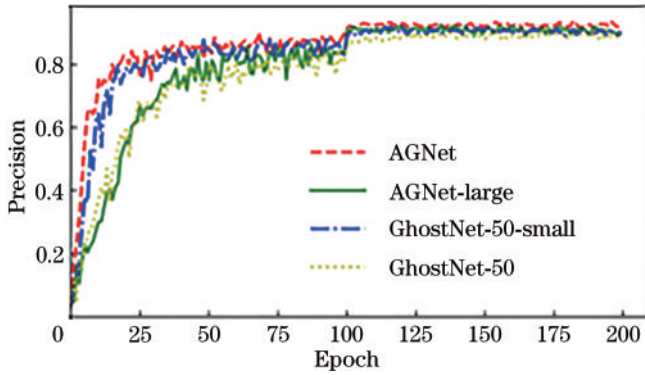


图 7 测试集精度对比曲线

Fig 7 Comparison curve of test set set precision

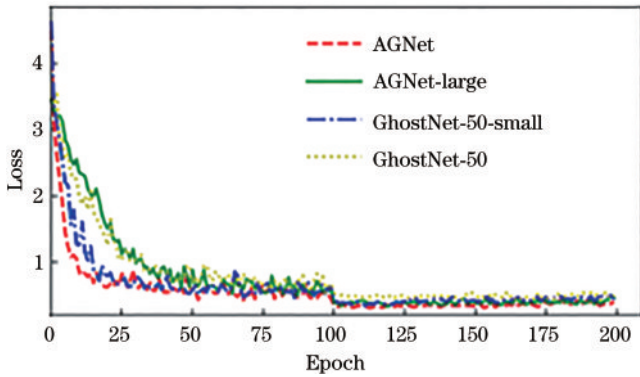


图 8 测试集损失值对比曲线

Fig 8 Comparison curve of test set loss value

GhostNet-50 提升了 1.09 个百分点。通过对比图 7 中 GhostNet-small-50 和 GhostNet-50 的对比曲线,可以看出在训练初始阶段,去掉  $1 \times 1$  Conv 之后的 GhostNet-small-50 具有更高的测试精度,图 8 反映出 GhostNet-small-50 随着训练次数的增加,收敛速度更快。实验结果表明, GhostNet-50 中未去掉的  $1 \times 1$  Conv 参数占比较大,存在一定的参数冗余,去掉  $1 \times 1$  Conv 之后,可以提升船舶分类模型的精度、推理性能,以及模型训练过程的收敛速度。通过对比 AGNet 和 AGNet-large,同样可以得出一致的结论。

表 4 船舶样本类别下的各网络性能对比

Table 4 Comparison of each network performance

Model	Multiply-accumulate operations / $10^6$	Parameters / $10^6$	Accuracy /%	Speed / (frame·s <sup>-1</sup> )
AGNet	49.35	0.73	93.55	46.93
AGNet-large	49.97	1.39	90.32	41.24
GhostNet-50	45.84	1.38	87.60	42.97
GhostNet-50-small	45.22	0.72	92.94	49.64

对比表 3 中 AGNet-large 和 GhostNet-50 的数据可知, AGNet-large 参数量和运算量相比 GhostNet-50 分别提升了 9.01% 和 0.74%, 在推理速度上, AGNet-large 平均每秒比 GhostNet-50 少处理 1.82 张图片, 但 AGNet-large 的分类精度比 GhostNet-50 提升了 1.56% 个百分点。实验结果表明, 采用非对称 Ghost 模块可以提升 Ghost 模块的特征提取能力。较之采用普通 Ghost 模块的网络 (GhostNet-50-small, GhostNet-50), 采用非对称 Ghost 模块的网络 (AGNet, AGNet-large) 在增加有限运算成本和较少参数成本的前提下, 进一步提升了船舶分类模型的精度。

对比表 3 中 AGNet 和 GhostNet-50 的数据可知, AGNet 相比 GhostNet-50 增加了 7.66% 的运算量。但模型参数量相比 GhostNet-50 降低了 46.67%。且分类精度相比 GhostNet-50 提升了 2.93 个百分点。从模型推理速度来看, AGNet 平均每秒比 GhostNet-50 多处理 4.15 张船舶图片, 相比 GhostNet-50 仍然具有一定的优势。由图 7 可知, AGNet 在训练初始阶段相比 GhostNet-50 分类精度更高, 在图 8 中表现为损失值收敛更快。以上实验结果表明, AGNet 在增加较少运算量的情况下, 相比 GhostNet-50 具有更低的模型参数和更高的推理速度, 且模型的分类精度更高, 验证了 AGNet 所提方法的有效性。

为分析 AGNet 在更多船舶样本类别上的表现, 在 59 个船舶样本类别上分别对图 6 中的 4 个网络进行了训练和测试, 表 4 列出了上述 4 个网络分别在运算量、参数量、测试精度、模型推理速度方面的对比情况。

表 4 中, AGNet 相比其他 3 个网络具有更高的测试精度, 验证了 AGNet 在更多类别数据的分类上仍具有一定的性能优势。对比表 4 和表 3 中的同一网络模型, 可以发现各网络的模型运算量几乎不变, 模型参数量仅有少量增加, 模型推理速度仅有少量降低, 表明了分类类别数的增加不会对模型参数量、运算量、模型推理速度造成较大影响。在分类精度的对比上, AGNet 和 GhostNet-50-small 在 59 个类别上的分类精度相比在

33 个类别上的分类精度分别降低了 0.32 个百分点和提升了 0.91 个百分点,而 AGNet-large 和 GhostNet-50 在 59 个类别上的分类精度相比在 33 个类别上的分类精度分别降低了 2.18 个百分点和 3.34 个百分点。实验结果表明,在更多样本的分类任务中,各网络的分类性能均有一定变化,但 AGNet 相比 GhostNet-50-small 仍具有更好的分类性能,论证了提出的非对称 Ghost 瓶颈模块相比 Ghost 瓶颈模块具有更好的学习能力。同时,相比未去掉  $1 \times 1$  Conv 模块的 AGNet-large 和 GhostNet-50,去掉  $1 \times 1$  Conv 模块的 AGNet 和 GhostNet-50-small 能使分类模型具有更强的鲁棒性。

表 5 不同分类网络对比结果

Table 5 Comparison results of different classification networks

Model	Multiply-accumulate operations / $10^6$	Parameters / $10^6$	Accuracy / %
MobileNetV3-small-100 <sup>[24]</sup>	70.06	2.54	87.81
ResNet18 <sup>[1]</sup>	1821.66	11.69	89.84
DPN-68b <sup>[26]</sup>	2338.55	12.61	91.87
RegNetx-002 <sup>[27]</sup>	200.69	2.68	89.53
GhostNet-50 <sup>[23]</sup>	45.84	1.35	92.50
AGNet	<b>49.35</b>	<b>0.72</b>	<b>93.87</b>

由表 5 可知,AGNet 相比轻量化模型 MobileNetV3-small-100 和 RegNetx-002 具有更低的参数量以及运算量,且模型精度分别比 MobileNetV3-small-100 和 RegNetx-002 提升了 6.06 个百分点和 4.34 个百分点。同时,相比高运算量的 ResNet18 和 DPN-68b,AGNet 的模型精度仍能提升 4.03 个百分点和 2 个百分点。实验结果表明,相比当前主流的网络架构,设计的 AGNet 军舰分类模型具有更高的分类精度,且模型参数量和运算量更低。

## 4 结 论

在船舶分类实际应用中,为平衡分类模型的精度和存储空间,提出一种轻量级的 AGNet 船舶分类模型,该模型主要对 GhostNet-50 进行改进。实验过程中,用自制的船舶数据集对 AGNet 进行训练和测试,并采用多种评价指标来综合验证 AGNet 在船舶分类任务中的有效性。实验结果表明,与 GhostNet-50 相比,训练的船舶分类模型 AGNet 具有更高的分类精度和更低的模型参数。同时,相比当前主流的分类模型,AGNet 在船舶分类任务中同样具有一定的优势,其模型参数量和运算量更少、分类精度更高,进一步验证了 AGNet 能较好应用到船舶分类场景中。未来将继续从实际应用出发,不断研究和改进船舶分类相关算法,权衡相关评价指标,设计性能更优良的船舶分类模型。

## 参 考 文 献

[1] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-

综合表 3、图 7、图 8 及表 4 的实验结果及分析,AGNet 采用一种非对称的 Ghost 瓶颈模块替换 GhostNet-50 中的 Ghost 瓶颈模块,同时去掉 GhostNet-50 中的  $1 \times 1$  Conv,相比 GhostNet-50 具有更低的参数量,在船舶分类任务中具有更好的分类精度,并为船舶分类模型的推理加速提供有力支撑。

### 3.5 不同网络结构的对比验证

为进一步验证 AGNet 分类模型的有效性,采用当前主流的分类网络来训练 33 类船舶数据集,并在分类精度、模型参数量、模型计算量等 3 个方面作对比。实验对比结果见表 5。

- 30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [2] Li X M, Chen H, Qi X J, et al. H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes[J]. IEEE Transactions on Medical Imaging, 2018, 37(12): 2663-2674.
- [3] Zhang X Y, Zou J H, He K M, et al. Accelerating very deep convolutional networks for classification and detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(10): 1943-1955.
- [4] 张典,汪海涛,姜瑛,等.基于轻量级网络的实时人脸识别算法研究[J].计算机科学与探索,2020,14(2):317-324. Zhang D, Wang H T, Jiang Y, et al. Research on real-time face recognition algorithm based on lightweight network[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(2): 317-324.
- [5] 孙文斌,王荣,孙连焘,等.基于深度学习的跨年龄人脸识别[J].激光与光电子学进展,2022,59(2):0215001. Sun W B, Wang R, Sun L Z, et al. Cross-age face recognition based on deep learning[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0215001.
- [6] 宋敏毓,陈力荣,梁建安,等.轻量化改进网络的实时光纤端面缺陷检测模型[J/OL].激光与光电子学进展:1-21[2021-11-15]. <http://kns.cnki.net/kcms/detail/31.1690.tn.20211110.1211.010.html>. Song M Y, Cheng L R, Liang J A, et al. Real-time optical fiber end surface defects detection model based on lightweight improved network[J/OL]. Laser & Optoelectronics Progress: 1-21[2021-11-15]. <http://kns.cnki.net/kcms/detail/31.1690.tn.20211110.1211.010.html>.
- [7] 刘金香,班伟,陈宇,等.融合多维度 CNN 的高光谱遥感图像分类算法[J].中国激光,2021,48(16):1610003. Liu J X, Ban W, Chen Y, et al. Multi-dimensional CNN

- fused algorithm for hyperspectral remote sensing image classification[J]. Chinese Journal of Lasers, 2021, 48(16): 1610003.
- [8] 王文秀, 傅雨田, 董峰, 等. 基于深度卷积神经网络的红外船只目标检测方法[J]. 光学学报, 2018, 38(7): 0712006. Wang W X, Fu Y T, Dong F, et al. Infrared ship target detection method based on deep convolution neural network[J]. Acta Optica Sinica, 2018, 38(7): 0712006.
- [9] 侯笑晗, 金国栋, 谭力宁. 基于深度学习的 SAR 图像舰船目标检测综述[J]. 激光与光电子学进展, 2021, 58(4): 0400005. Hou X H, Jin G D, Tan L N. Survey of ship detection in SAR images based on deep learning[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0400005.
- [10] 王燕妮, 孙雪松, 余丽仙. 增强感受野的轻量化合成孔径雷达船舶检测算法[J]. 光子学报, 2022, 51(2): 0210008. Wang Y N, Sun X S, Yu L X. Lightweight synthetic aperture radar ship detection algorithm with enhanced receptive field[J]. Acta Optica Sinica, 2022, 51(2): 0210008.
- [11] 毕振波, 张世友, 杨花, 等. 基于浅层机器学习的视频监控船舶检测综述[J]. 系统仿真学报, 2021, 33(12): 2792-2807. Bi Z B, Zhang S Y, Yang H, et al. Survey of ship detection in video surveillance based on shallow machine learning[J]. Journal of System Simulation, 2021, 33(12): 2792-2807.
- [12] 陈雯. 基于视频处理技术的船舶移动位置跟踪研究[J]. 舰船科学技术, 2019, 41(20): 40-42. Chen W. Research on ship moving position tracking based on video processing technology[J]. Ship Science and Technology, 2019, 41(20): 40-42.
- [13] 王爱丽, 刘美红, 薛冬, 等. 结合动态卷积和三重注意力机制的高光谱图像分类[J]. 激光与光电子学进展, 2022, 59(10): 1015011. Wang A L, Liu M H, Xue D, et al. Hyperspectral image classification combined dynamic convolution with triplet attention mechanism[J]. Laser & Optoelectronics Progress, 2022, 59(10): 1015011.
- [14] 任永梅, 杨杰, 郭志强, 等. 基于三维卷积神经网络的点云图像船舶分类方法[J]. 激光与光电子学进展, 2020, 57(16): 161022. Ren Y M, Yang J, Guo Z Q, et al. Ship classification method for point cloud images based on three dimensional convolutional neural network[J]. Laser & Optoelectronics Progress, 2020, 57(16): 161022.
- [15] 陈兴伟. 深度学习船舶分类技术研究[J]. 舰船科学技术, 2019, 41(14): 142-144. Chen X W. Research on ship classification technology based on deep learning[J]. Ship Science and Technology, 2019, 41(14): 142-144.
- [16] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [17] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning[C]//AAAI'17: Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, February 4-9, 2017, San Francisco, California, USA. Menlo Park: AAAI Press, 2017: 4278-4284.
- [18] Tan M X, Le Q V. Efficientnet: Rethinking model scaling for convolutional neural networks[C]//Proceedings of the 36th International Conference on Machine Learning, {ICML} 2019, June 9-15, 2019, Long Beach, California, USA. Cambridge: PMLR, 2019: 6105-6114.
- [19] Howard A G, Zhu M, Chen B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017-04-17)[2021-09-29]. <https://arxiv.org/abs/1704.04861>.
- [20] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4510-4520.
- [21] 肖振久, 杨晓迪, 魏宪, 等. 改进的轻量型网络在图像识别上的应用[J]. 计算机科学与探索, 2021, 15(4): 743-753. Xiao Z J, Yang X D, Wei X, et al. Improved lightweight network in image recognition[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(4): 743-753.
- [22] Wang G R, Wang K Z, Lin L. Adaptively connected neural networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 1781-1790.
- [23] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1577-1586.
- [24] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 1314-1324.
- [25] Iandola F N, Han S, Moskewicz M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size[EB/OL]. (2016-11-04)[2021-09-29]. <https://arxiv.org/abs/1602.07360>.
- [26] Chen Y, Li J, Xiao H, et al. Dual path net-works[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, December 4-7, 2017, Long Beach, California, USA. New York: Curran Associates Inc., 2017: 4470-4478.
- [27] Radosavovic I, Kosaraju R P, Girshick R, et al. Designing network design spaces[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 10425-10433.