

基于改进 ResNet18 的遥感图像舰船目标识别^{*}

曾富强 张贞凯 方梦瑶

(江苏科技大学海洋学院 镇江 212003)

摘要: 舰船作为主要的海上交通作战工具,在遥感图像中高效准确识别舰船目标具有重要研究意义。光学遥感舰船图像包含丰富的信息,但因其具有复杂度高、图像大、受天气和昼夜变化影响等特点,导致识别率较低。针对这一问题,本文通过对 ResNet18 进行改进,提出一种更加高效的光学遥感舰船图像分类的方法。对 ResNet18 网络进行了简化,降低其参数量;使用并行池化实现特征图的空间降维,在保持特征丢失较少的情况下加快网络收敛;引入多尺度卷积进行不同尺度特征信息的提取,并使用 ECA 注意力机制改进多尺度卷积模块与残差模块,解决分支网络支路融合时存在特征不能很好的在通道间交互的问题。在 FGSCR-42 数据集上进行实验,实验结果表明改进后的算法收敛速度更快,且准确率与 F1-score 均高达 95% 左右,较 ResNet18 网络提高了 7% 左右,而参数量仅有改进前的 20% 左右;与其他网络在舰船目标识别中的性能相比,本文方法也更加出色。

关键词: 图像分类;卷积神经网络;ResNet18;注意力机制;遥感舰船图像

中图分类号: TN919.8; TP751 文献标识码: A 国家标准学科分类代码: 510.40

Ship target recognition in remote sensing images based on improved ResNet18

Zeng Fuqiang Zhang Zhenkai Fang Mengyao

(Ocean College, Jiangsu University of Science and Technology, Zhenjiang 212003, China)

Abstract: As the main means of Marine traffic warfare, it is of great significance to identify ship targets efficiently and accurately in remote sensing images. Although the optical remote sensing ship image contains rich information, the recognition rate is low because of its high complexity, large image and the influence of weather and day and night change. To solve this problem, this paper proposes a more efficient optical remote sensing ship image classification method by improving ResNet18. The ResNet18 network is simplified and its parameter number is reduced. The parallel Pooling is used to reduce the dimensionality of the feature graph space to speed up the network convergence while keeping less feature loss. The multi-scale convolution is introduced to extract feature information of different scales, and the ECA attention mechanism is used to improve the multi-scale convolution module and residual module to solve the problem that features can't interact well between channels in branch network branch fusion. Experiments were carried out on the FGSCR-42 dataset, and the experimental results show that the improved algorithm converges faster, and the accuracy and F1-score are up to about 95%, which is about 7% higher than that of the ResNet18 network, while the number of parameters is only about 20% of that before the improvement. Compared with the performance of other networks in ship target recognition, the proposed method also has better performance.

Keywords: image classification; convolutional neural network; ResNet18; attention mechanism; remote sensing ship image

0 引言

随着人类航运技术和海洋探索等发展,目前海洋已成为重要的交通通道^[1]。舰船是最主要的海上交通工具,也

是重要的军事重器,在给人类的生产和生活等方面带来最大便利的同时也关系到国家安全和领土完整。随着相关技术的发展,海洋交通状况趋于复杂,舰船在军事领域中也愈加重要。卫星、无人机等遥感平台的出现,使得遥感技术成功

应用于海洋监测领域,如何在海洋监测到的图像中准确地识别出舰船目标具有重要研究意义^[2],这也对于国家海洋边防安全和海上交通监测管理具有重要价值^[3]。

传统的图像识别算法主要根据图像的颜色、形状、纹理等特征来实现,基于手工设计特征提取算法实现特征的提取。遥感舰船图像具有目标尺寸差异大、背景复杂、不同类目标间差异小和同类目标间差异大等特点,这导致基于传统的图像识别算法进行舰船目标识别的准确率低,不足以满足实际应用要求^[4]。

深度学习诞生于 20 世纪 40 年代,随着计算机计算能力和内存的快速提升,深度学习得到快速发展,被广范应用于各个领域^[5]。尤其卷积神经网络(convolutional neural network,CNN)在图像领域取得了引人注目的效果^[6],如 LeNet、AlexNet、VGG、GoogLeNet 和 ResNet 等都是卷积神经网络的代表性成果,其中 ResNet 网络^[7]是由 Kaiming He 等人于 2015 年提出的,该网络利用残差网络模块解决了 VGG 网络在大幅度增加深度时梯度消失导致“网络退化”的问题。

近年来,CNN 也被广泛应用于舰船目标检测识别中。马啸等^[8]借鉴 YOLO 的回归思想,设计出一个简化的 YOLO 模型 Simple-YOLO 用于舰船目标识别,召回率达到了 92.1%。张筱晗等^[9]以舰船目标中心点检测为基础,通过卷积神经网络融合高、低层特征信息得到特征图,并通过 3 个检测分支进行舰船目标的斜框检测,准确率达到 90.6%。徐安林等^[10]为解决遥感图像中舰船目标检测率低、虚警率高的问题,提出一种结合层次化搜索与视觉残差网络的舰船目标检测方法,实现了复杂环境下光学舰船的准确、高效检测定位。龙昊等^[11]为了解决深度学习在处理数据集较小图像上无法准确提取特征及数据相似度较高的问题,基于 YOLOv5-ResNet 提出了一种跨尺度融合机制,重新定义损失函数,在舰船目标检测上最高准确率达到 93%。刘源洞等^[12]基于 ResNet50 和改进注意力机制提出一种舰船目标识别网络模型,在验证集上最高识别率达到 95.5%。陈华杰等^[13]提出一种基于源域样本相关性排序的跨域迁移学习算法用于小样本舰船目标识别,识别精度提升了 17.59%。

目前,用于舰船目标检测识别的数据集中的图像主要有合成孔径雷达(synthetic aperture radar, SAR)图像、光学图像、红外图像和高光谱图像。其中 SAR 图像与可见光图像应用更为广泛,SAR 图像可读性较差,无法提供舰船纹理、色彩等特征,不适合用于舰船目标细粒度识别;而可见光图像具有丰富的特征信息,在舰船目标的细粒度识别上更有优势,但由于其具有背景复杂度高、图像数据量大,易受天气昼夜变化影响等特点,导致舰船目标识别效果并不理想^[14]。

针对上述情况,本文基于 ResNet18 进行改进,提出一种光学遥感舰船图像的细粒度识别方法:在 ResNet18 基础

上先进行网络简化,降低参数冗余;然后引入多尺度卷积、通道注意力机制,分别从空间与通道维度上提高算法的特征提取能力;并行最大、均值池化实现特征图的空间降维,在保持特征丢失较少的情况下加快网络收敛。实验结果表明改进后的网络模型在遥感舰船图像的分类上表现更优。

1 数据处理与数据增强

本文实验中采用数据集为 FGSCR-42 数据集,该数据集由 9 320 张像素大小从 50×50~1 500×1 500 左右不同的光学卫星遥感舰船目标图像组成。根据舰船用途、所属国家、舰船型号等,该数据集被划分为 42 个类别,其中部分类别样本数量过少,存在样本不均衡情况;其次,该数据中舰船目标多停靠在码头边,且存在少部分两种船在一张图像上的情况。如图 1 所示为数据中的部分图像^[15]。



图 1 FGSCR-42 数据集图像示例

Fig. 1 Sample images of the FGSCR-42 dataset

本文按舰船用途,将该数据集归类为 16 类进行实验,详细信息如表 1 所示。训练前使用 Pytorch 框架下图像增强函数 transforms 对数据集进行尺度统一、中心化、标准化、随机旋转、平移、去雾、加高斯白噪声等方式进行了数据增强预处理^[16]。由于设备资源限制,数据增强前后不进行数据的扩增。

表 1 数据集的构成

Table 1 Composition of the dataset

类别 序号	类别 名称	训练集 样本数量	测试集 样本数量
1	医疗舰	241	81
2	巡洋舰	455	152
3	战斗舰	288	96
4	护卫舰	66	22
5	拖船	583	195
6	支援船	37	13
7	攻击舰	343	115
8	油船	120	40
9	游艇	706	236
10	登陆舰	294	99
11	载沙船	169	57
12	航母	689	230
13	货船	283	95
14	起重船	106	36
15	运输码头	243	82
16	集装箱船	341	114

2 算法原理

2.1 ResNet18 网络模型

ResNet 主要是在 VGG 网络的基础上进行改进得到的,它在网络中创新性地提出了残差模块,如图 2 所示,它通过 identity 连接将卷积的输入 x 和输出 $F(x)$ 直接相加,然后通过激活函数 σ ,最后模块输出 y ,计算公式为:

$$F(x) = W_2\sigma(W_1x) + b \tag{1}$$

$$y = \sigma(F(x) + x) \tag{2}$$

式中: W_1 与 W_2 分别指两个 Weight layer 操作中的卷积运算, b 指整个支路操作中的偏移量,Weight layer 由卷积层和归一化层组合而成。




图 2 残差模块结构

Fig. 2 Residual module structure

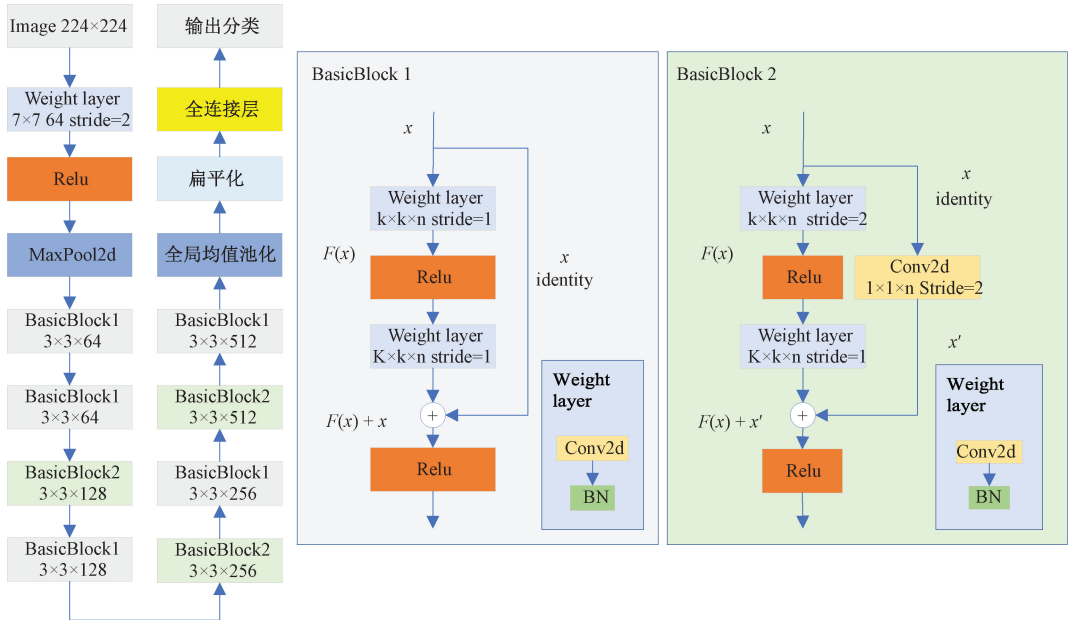


图 3 ResNet18 网络的结构

Fig. 3 Structure of ResNet18 network

用并行池化 Pool_2branch 实现特征图的空间降维;基于通道注意力机制,改进残差模块 BasicBlock2 模块得到 BasicBlock_z 模块,提出 Inception_z 多尺度卷积模块。

ResNet 网络根据实际解决问题的复杂程度,按网络的深度分为不同版本,常见有 ResNet18、ResNet34、ResNet50、ResNet101、ResNet152 等,针对于本文舰船目标分类而言,ResNet 系列网络的识别效果并没有随着网络深度的增加而有显著提升,为了节约存储、计算量等资源,因此本文将在 ResNet18 的基础上进行舰船目标识别的研究。

如图 3 所示为 ResNet18 网络的结构,该网络输入图像大小为 224×224 ,第一层卷积通过调整步长为 2 来降维,得到大小为 112×112 的特征图,紧接着又使用最大池化进一步降维,输出特征图的大小为 56×56 ,导致过度降维,使得图像特征丢失;在残差模块中,主支路进行两次卷积,实际上一层卷积就可以实现特征的提取,而 2 次卷积增加了网络的参数量;网络对同一大小的特征图通过 2 次残差模块提取特征,这些使得网络参数增大,容易出现过拟合;该网络卷积核大小一直是 3×3 ,不能很好地进行对不同尺度特征的提取。因此本文针对 ResNet18 网络存在的以上问题进行改进,提出一种基于改进 ResNet18 的网络模型进行遥感舰船图像的分类。

2.2 基于改进 ResNet18 的网络模型

如图 4 所示为基于 ResNet18 改进后的网络模型,与原网络模型相比,简化了网络模型,将第一层卷积的卷积核大小改成 3×3 、输出通道数调整为 16,去除第一层卷积后的池化层,去除网络中的恒等残差模块 BasicBlock1 模块;使

高效通道注意力机制 (efficient channel attention, ECA) 是一种轻量化的通道注意力机制,它从特征图中学习到通道权重值向量并与特征图相乘,增大了含有重要特

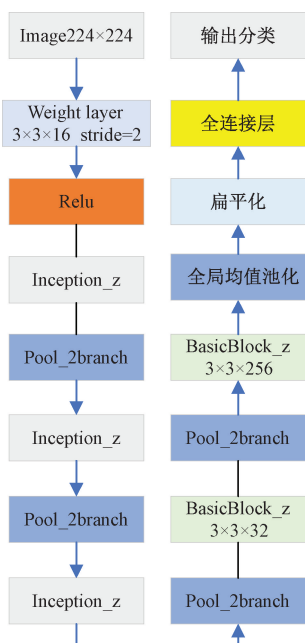


图 4 基于 ResNet18 改进后的网络结构

Fig. 4 Structure of improved network based on ResNet18

征信息通道的权重,降低了无关特征通道的权重,增强了网络的特征提取能力^[17]。如图 5 所示为 ECA 的模型结构,它首先使用全局均值池化到的一维特征向量;再通过一维卷积实现跨通道间的信息交互,并得到特征通道权重,该一维卷积的卷积核大小 k 通过式(3)所示函数自适应变化;最后使用 sigmoid 函数得到通道权重向量并于特征图相乘,得到输出。

$$k = \left\lceil \frac{\log_2(c) + b}{\gamma} \right\rceil \quad (3)$$

式中: $\gamma=2, b=1, c$ 指输入特征图的通道数。

如图 6 所示,本文将残差模块中的第二层卷积除去,在网络性能下降不大的同时降低了参数量;本文在支路特




图 5 ECA 注意力机制结构

Fig. 5 Structure of ECA attention mechanism

征求和前,在各支路引入了 ECA 模块,这样有利于增大含有重要特征信息通道的权重,降低了无关特征通道的权重,改善了残差结构在通道间信息流通不足,从而增强了网络的特征提取能力。




图 6 BasicBlock_z 结构

Fig. 6 Structure of BasicBlock_z

ResNet18 网络中单一的使用了 3×3 的卷积进行特征提取,很难提取到不同尺度的特征信息,结合 Inception 并行多尺度卷积提取特征的思想,如图 7 所示,本文根据舰船目标形状多为矩形,因此并行使用 $3 \times 3, 1 \times 3, 3 \times 1$ 及连续使用两个 3×3 的卷积进行特征提取,同时使用 1×1 的卷积实现通道的升维;由于并行多尺度卷积也存在残差

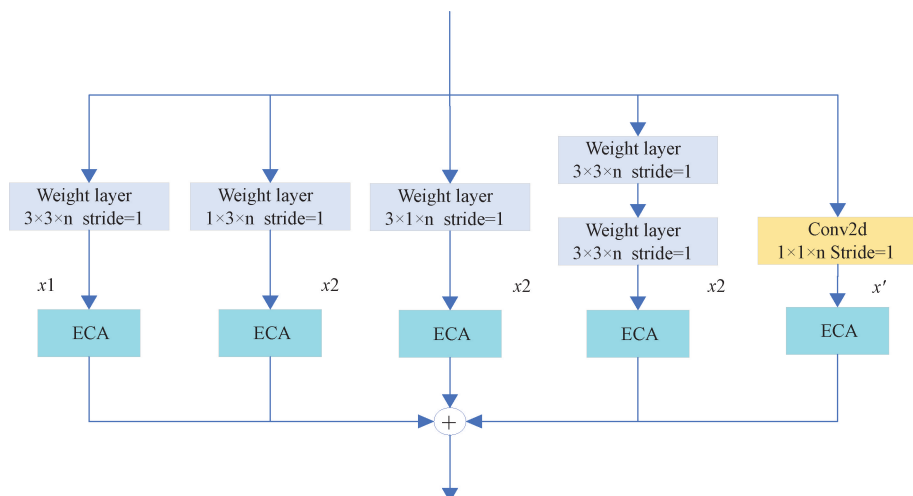


图 7 Inception_z 结构

Fig. 7 Structure of Inception_z

模块支路特征融合没有进行通道间的信息交互,因此在各支路同样使用 ECA 模块来实现通道间的信息交互,并增强对重要特征通道的关注度,抑制非重要特征的干扰。

常通过控制卷积步长或是池化层来实现对特征图进行空间降维,相比卷积而言,池化层参数量要少很多、收敛速度更快。常用池化有均值池化与最大池化,均值池化能够很好的考虑到所有特征信息,但收敛速度慢;而最大池化能够快速的提取特征,收敛速度快,但其也会丢弃一部分特征信息,尤其在多维特征时,特征图的每一个像素点都含有比较重要特征信息,因此容易导致特征丢失^[18]。如图 8 所示,为了弥补均值池化与最大池化的不足,本文采用并行均值和最大池化的方法进行特征图的空间降维,并在支路融合处给两支路求加权和,舰船目标分类更注重纹理信息,为了加速网络收敛,因此,给予最大池化支路更大的权重。




图 8 Pool_2branch 结构
Fig. 8 Structure of Pool_2branch

3 实验与分析

3.1 实验环境

为了验证所提方法的有效性,本文采用 FGSCR-42 数据集进行实验,按 7 : 3 的比例将数据集划分为训练集和测试集。实验使用 PC 系统参数如表 2 所示,网络训练超参数如表 3 所示。

表 2 系统参数
Table 2 System parameters

配置	参数
CPU	AMD Ryzen 7 6800H
GPU	NVIDIA GeForce RTX 3070 Ti
操作系统	Windows 11 x64
深度学习框架	Pytorch 2.0.0+cu117
Python 版本	Python 3.11

3.2 性能评估指标

本文实验属于多分类问题,常用于评估多分类问题的性能指标有准确率 (accuracy, Acc)、精准率 (precision, P)、召回率 (recall, R) 以及 F1-score 等^[19]。具体计算公式为:

表 3 超参数

Table 3 Hyperparameters

超参数	值
输入图像大小	224×224
初始学习率	0.001
批量大小	128
训练轮次	20
优化器	AdamW
损失函数	交叉熵损失函数

$$Acc = \frac{\text{分类正确样本数}}{\text{总样本数}} \tag{4}$$

$$P_i = \frac{\text{分类为 } i \text{ 类中正确样本数}}{\text{分类为 } i \text{ 类样本数}} \tag{5}$$

$$R_i = \frac{i \text{ 类中被正确分类样本数}}{i \text{ 类样本数}} \tag{6}$$

$$P = \sum_{i=1}^N P_i \frac{\text{分类为 } i \text{ 类样本数}}{\text{总样本数}} \tag{7}$$

$$R = \sum_{i=1}^N R_i \frac{i \text{ 类样本数}}{\text{总样本数}} \tag{8}$$

$$F1-score = \frac{2P \times R}{P + R} \tag{9}$$

式中: P_i 、 R_i 分别表示某一类的精准度, N 为测试集总的类别数。

本文实验数据集每类样本的数量差异大,用 Acc 评估可能因样本数大的类别影响,不能全面的评估网络性能,因此本文采用 Acc 与 F1-score 作为网络识别性能的评估指标,二者值越大表示网络性能越好。

同时,本文采用参数量和计算量衡量网络模型的大小和识别速度。在卷积神经网络中参数量主要集中在卷积层和全连接层,下式为卷积层和全连接层参数计算公式:

$$Pa_c = C_{out} \times K_w \times K_h \times C_{in} + bias \tag{10}$$

$$bias = C_{out} \tag{11}$$

$$Pa_f = C_{in} \times W \times H + C_{out} \tag{12}$$

式中: Pa_c 、 Pa_f 分别为卷积层、全连接层参数量, C_{in} 、 C_{out} 分别为对于网络层输入、输出特征图通道数, $bias$ 指卷积层卷积运算的偏移量, K_w 、 K_h 分别为卷积层卷积核的宽、高, W 、 H 分别为全连接层输入特征图的宽、高。整个网络的参数量约等于整个网络中所有卷积层和全连接层的参数量总和。

CNN 的计算量是指网络模型处理一张图像所进行的浮点运算总次数,它由网络本身和图像像素大小共同决定,计算机中将进行一次加或乘运算都算一次浮点运算,而在计算机视觉中常将一次加和乘运算算作一次浮点运算。CNN 的计算量在网络的每一层都有,下式为卷积层和全连接层中计算量的计算公式:


$$F_c = Pa_c \times W \times H \tag{13}$$

$$F_f = Pa_f \times W \times H \tag{14}$$

式中: F_c 、 F_f 分别为卷积层和全连接层的计算量, Pa_c 、

Pa_f 分别为卷积层、全连接层参数量, W 、 H 分别为对应网络层中输入特征图的宽、高。整个网络模型中还有归一化层、激活层、池化层等这些层中也有对应的计算量,在此不再详细介绍。

本文实验中计算量、参数量直接使用 Python 中的 thop 资源包中 params_flops 函数计算得到。



3.3 网络训练与测试

本文使用 FGSCR-42 数据集进行网络的训练,将数据集划分为 16 类,具体分类及数据量可参考本文数据处理与数据增强部分,如图 9 所示为网络训练过程中准确率与损失的变化曲线,可以看出从第 10 轮左右开始网络的损失值不在下降,准确率不在上升,网络趋于收敛。




图 9 性能指标的变化曲线
Fig. 9 Variation curve of performance indicators

如图 10 所示为测试结果的混淆矩阵,该图中, Y 坐标表示实际类别, X 坐标表示预测类别,对角线为每一类别识别正确的样本数量;每一类识别正确样本数与所在列所有样本数量之比即为该类准确率,标注在图像最下面一行;每一类识别正确样本数与所在行所有样本数量之比即为该类召回率,标注在图中最右侧一列;右下角表示准确率,是所有预测正确样本数量与总样本数量之比,可看出为 94.7%。




图 10 混淆矩阵
Fig. 10 Confusion matrix

3.4 消融实验

为了验证本文改进方法中各种改进点对网络性能的影响,所以对模型进行消融实验,结果如表 4 所示。其中模型 A、B、C、D、E 分别代表 ResNet18、简化后的网络模型、使用并行池化的模型、加入 Inception_z 模型以及引入 ECA 改进残差模块后网络。

表 4 消融实验
Table 4 Ablation experiments

模型	Acc/ %	F1-score/ %	参数量/ M	计算量/ $\times 10^9$ FLOPs
A	88.4	88.3	11.18	1.82
B	80.6	81.3	1.76	0.09
C	90.8	91.5	1.76	0.34
D	93.1	93.2	2.10	0.99
E	95.3	95.4	2.12	1.18

由表 4 可以知,模型 B 尽管 Acc 与 F1-score 均低于 ResNet18,但参数量却得到大幅度的降低;模型 C、D、E 的 Acc 与 F1-score 均高于 ResNet18,尤其模型 E 的 Acc 与 F1-score 均高达 95% 左右,较 ResNet18 提高了 7%,而且参数量和计算量得到了大幅度的减小。综上所述,本文改进后的算法相比于 ResNet18 在性能上有显著提升,证明改进方法的有效性。

3.5 Grad-CAM 特征可视化

梯度加权类激活映射方法 (gradient-weighted class activation mapping, Grad-CAM)^[20] 常用于可视化 CNN 模型的决策区域,其对于提高深度学习网络模型的可解释性

具有良好效果。本文使用该方法分别对训练好的 ResNet18 和改进后的网络进行可视化实验,如图 11(a)、(b)所示分别为 2 类舰船在 ResNet18 和本文改进后的网络中由浅到深 4 个中间层提取到的特征热力图,蓝色程度越深,说明特征所占权重越低,红色程度越深,说明特征所占权重越高,对分类判别的贡献越高。可以看出网络在浅层更关注于纹理细节等小尺度特征,而在深层时会更关注于形状等大尺度的特征;其次,改进后网络的权重主要集中在关键特征上,而其他非重要特征的贡献权重相对较低,进而提高了网络的收敛速度和识别效果。




图 11 可视化特征热力图

Fig. 11 Visual characteristic heat map

3.6 与其他网络模型对比

为了进一步验证网络的性能,本文将改进后的网络与经典神经网络进行对比,实验数据集划分及预处理完全保持一致,如表 5 所示为对比试验结果,由表 5 可知,本文改进方法的性能,不论是 Acc、F₁-score,还是参数量、计算量,都优于实验对比组中的经典网络模型。

为了更好地对比网络模型在整个训练过程中的性能,如图 12 所示为整个训练过程中本文方法与一些经典网络模型的准确率随着训练轮次的变化曲线图,本文改进的方法在整个训练过程中识别率都优于其他几种经典网络,且收敛相对也比较快。

如表 6 所示为本文方法与其他光学遥感舰船目标识别方法的性能对比。文献[21]将开集识别方法融入到细粒度图像分类中,在 FGSCR-42 数据集上进行舰船目标 8 分类实验;文献[22]提出了一种基于改进 ResNet-152 的舰

表 5 对比实验

Table 5 Comparative experiments

模型	Acc/ %	F1-score/ %	参数量/ M	计算量/ ×10 ⁹ FLOPs
AlexNet	45.1	50.5	57.07	0.71
GoogLeNet	60.6	63.7	5.62	1.51
DensNet	88.1	89.4	6.97	2.90
ResNet34	78.5	79.6	21.29	3.68
ResNet18	88.4	88.3	11.18	1.82
本文	95.3	95.4	2.12	1.18

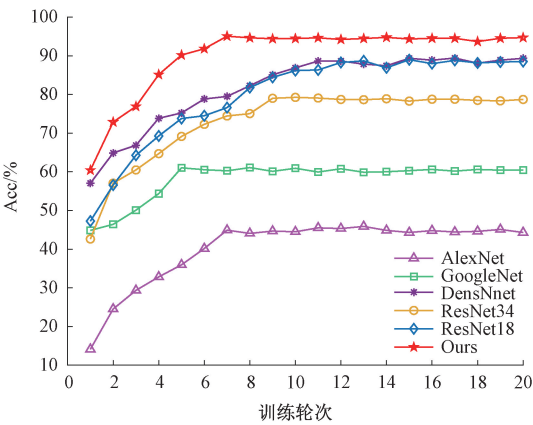


图 12 准确率随训练轮次变化曲线

Fig. 12 Variation curve of accuracy with training rounds

船目标识别方法,在 MARVEL 数据集上进行了舰船目标 5 分类实验;文献[23]提出一种基于视觉注意力网络(VAN-MR)的 Metaformer 和残差融合网络用于舰船目标的细分类研究;文献[24]提出了一种多特征集成学习分类模型(MFELCM)用于舰船目标 4 分类;本文在 FGSCR-42 数据集上进行舰船目标 16 分类实验,且性能指标准确率和 F1-score 均取得不错效果。

表 6 遥感舰船目标识别算法性能对比

Table 6 Performance comparison of remote sensing ship target recognition algorithms

模型	数据集	类别数	Acc/ %	F1-score/ %
文献[21]	FGSCR-42	8	90.0	91.9
文献[22]	MARVEL	5	95.8	95.8
文献[23]	FGSC-23	23	91.1	89.7
文献[24]	Space-Based AIS Data	4	90.1	90.2
本文	FGSCR-42	16	95.3	95.4

综上所述,本文方法在光学遥感图像舰船目标细粒度识别上具有良好的识别性能。

3.7 HRSC2016 数据集实验

为了验证本文方法的在其他数据集上的识别效果,因此,在 HRSC2016 数据集^[25]上进行了实验,该数据集通过标签切片划分为航母、潜艇、军用和民用 4 类。数据集在用于网络训练、测试前只进行了尺度归一化、分布归一化等预处理,预处理前后不进行数据扩增,数据集信息和实验结果如表 7 所示。

表 7 改进前后算法的性能对比

Table 7 Performance comparison of the algorithm before and after the improvement

模型	Acc/%	F1-score/%
Rsenet18	73.1	76.9
本文	87.5	88.3

由表 7 可知,尽管在 HRSC2016 数据集上,本文方法和 ResNet18 性能相较有所下降,但本文方法的识别性能仍均要优于改进前的 ResNet18,证明本文方法的有效性。

4 结 论

本文提出一种基于改进 ResNet18 的光学遥感图像舰船目标识别方法,并在 FGSCR-42 数据集上进行一系列实验,实验结果表明改进后的算法在准确率与 F1-score 等评估指标上均优于原算法,且网络模型更小、收敛速度更快;为了进一步验证本文方法的优越性,与其他网络进行对比试验,实验结果表明本文方法的性能也优于其他对比算法;在 HRSC2016 数据集上进行实验,实验结果也表明本文方法有效。本文实验采用数据集中舰船目标多为大尺度码头目标,后续将在本文方法上进一步研究对小尺寸舰船目标检测识别^[26],其次,本文也发现单纯进行舰船目标识别容易受到一图多类舰船目标干扰,因此,在舰船目标的检测与识别中,舰船目标的检测与识别应该一起研究。

参考文献

[1] 周旗开,张伟,李东锦,等. 基于改进 YOLOv5s 的光学遥感图像舰船分类检测方法[J]. 激光与光电子学进展,2022,59(16):476-483.
ZHOU Q K, ZHANG W, LI D J, et al. Ship classification and detection method for optical remote sensing images based on improved YOLOv5s [J]. Laser & Optoelectronics Progress, 2022, 59 (16): 476-483.

[2] 宋志娜,李莎,杨建明,等. 基于特征与区域定位增强的遥感舰船目标检测[J]. 计算机工程,2023,49(8):257-264.
SONG ZH N, LI SH, YANG J M, et al. Remote sensing ship target detection based on feature and region localization enhancement [J]. Computer

Engineering, 2023, 49(8): 257-264.

[3] 姚红革,王诚,喻钧,等. 复杂卫星图像中的小目标舰船识别[J]. 遥感学报,2020,24(2):116-125.
YAO H G, WANG CH, YU J, et al. Recognition of small-target ships in complex satellite images [J]. Journal of Remote Sensing (Chinese), 2020, 24 (2): 116-125.

[4] 刘秋月,刘雪峰,孙绍华. 基于阴影增强和注意力机制的高光谱图像分类[J]. 电子测量技术,2023,46(8):14-23.
LIU Q Y, LIU X F, SUN SH H. Hyperspectral image classification based on shadow enhancement and attention mechanism [J]. Electronic Measurement Technology, 2023, 46(8): 14-23.

[5] 郑远攀,李广阳,李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用,2019,55(12):20-36.
ZHENG Y P, LI G Y, LI Y. Survey of application of deep learning in image recognition [J]. Computer Engineering and Applications, 2019, 55(12):20-36.

[6] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报,2017,40(6):1229-1251.
ZHOU F Y, JIN L P, D J. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017,40(6): 1229-1251.

[7] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. CoRR, 2015, DOI: abs/1512.03385.

[8] 马啸,邵利民,金鑫,等. 改进的 YOLO 模型及其在舰船目标识别中的应用[J]. 电讯技术,2019,59(8):869-874.
MA X, SHAO L M, JIN X, et al. Improved YOLO model and its application in ship target recognition[J]. Telecommunication Engineering, 2019, 59 (8): 869-874.

[9] 张筱晗,姚力波,吕亚飞,等. 基于中心点的遥感图像多方向舰船目标检测[J]. 光子学报,2020,49(4):210-218.
ZHANG X H, YAO L B, LYU Y F, et al. Center based model for arbitrary-oriented ship detection in remote sensing images [J]. Acta Photonica Sinica, 2020,49(4):210-218.

[10] 徐安林,牡丹,王海红,等. 结合层次化搜索与视觉残差网络的光学舰船目标检测方法[J]. 光电工程,2021,48(4):39-46.
XU AN L, DU D, WANG H H, et al. Optical ship target detection method combining hierarchical search and visual residual network [J]. Opto-Electronic Engineering, 2021, 48(4): 39-46.

- [11] 龙昊,张思佳,周晶,等.基于改进 YOLOv5-ResNet 的海上舰船 SAR 图像快速检测[J]. 宇航计测技术, 2024, 44(2):52-59.
LONG H, ZHANG S J, ZHOU J, et al. Rapid detection of SAR images of naval vessels based on improved YOLOv5-ResNet[J]. Journal of Astronautic Metrology and Measurement, 2024, 44(2):52-59.
- [12] 刘源洞,何茂征,黄益斌,等.基于 ResNet50 和改进注意力机制的船舶识别模型[J]. 计算机应用, 2024, 44(6):1935-1941.
LIU Y T, HE M Z, HUANG Y B, et al. Ship identification model based on ResNet50 and improved attention mechanism [J]. Journal of Computer Applications, 2024, 44(6): 1935-1941.
- [13] 陈华杰,吕丹妮,周泉,等.遥感图像小样本舰船识别跨区域迁移学习算法[J]. 遥感学报, 2024, 28(3):793-804.
CHEN H J, LYU D N, ZHOU X, et al. Cross-domain transfer learning algorithm for few-shot ship recognition in remote-sensing images [J]. National Remote Sensing Bulletin, 2024, 28(3): 793-804.
- [14] 赵其昌,吴一全,苑玉彬.光学遥感图像舰船目标检测与识别方法研究进展[J]. 航空学报, 2024, 45(8): 51-84.
ZHAO Q C, WU Y Q, YUAN Y B. Progress of ship detection and recognition methods in optical remote sensing images[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(8): 51-84.
- [15] YANGHUA D, ZHIGUO J, HAOPENG Z. A public dataset for fine-grained ship classification in optical remote sensing images[J]. Remote Sensing, 2021, 13(4): 747-747.
- [16] 刘颖,庞羽良,张伟东,等.基于主动学习的图像分类技术:现状与未来[J]. 电子学报, 2023, 51(10): 2960-2984.
LIU Y, PANG Y L, ZHANG W D, et al. Active learning-based image classification technology: status and future[J]. Acta Electronica Sinica, 2023, 51(10): 2960-2984.
- [17] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020:11531-11539.
- [18] 周航,黄春光,程海.基于全局多粒度池化的可见光红外行人重识别[J]. 电子测量技术, 2022, 45(1):122-128.
ZHOU H, HUANG C G, CHENG H. Visible infrared person re-identification based on global multi-granularity pooling [J]. Electronic Measurement Technology, 2022, 45(1): 122-128.
- [19] 谭章禄,陈孝慈.改进的分类器分类性能评价指标研究[J]. 统计与信息论坛, 2020, 35(9):3-8.
TAN ZH L, CHEN X C. Research on classification performance evaluation index of improved classifier [J]. Statistics & Information Forum, 2020, 35(9):3-8.
- [20] 李妙歌,陈渤,王东升,等.面向 SAR 图像目标分类的 CNN 模型可视化方法[J]. 雷达学报, 2024, 13(2): 359-373.
LI M G, CHEN B, WANG D SH, et al. CNN model visualization method for SAR image target classification[J]. Journal of Radars, 2024, 13(2): 359-373.
- [21] 柳长源,李婷,兰朝凤.细粒度遥感舰船开集识别[J]. 光学精密工程, 2023, 31(24):3618-3629.
LIU CH Y, LI T, LAN CH F. Fine-grained remote sensing ship open set recognition [J]. Optics and Precision Engineering, 2023, 31(24):3618-3629.
- [22] ASIMWE L L, YANG J. Ship classification based on improved convolutional neural network architecture for intelligent transport systems[J]. Information, 2021, 12(8): 302-302.
- [23] ZHOU G Q, HUANG L, SUN Q. Fine-grained classification of remote sensing ship images based on improved VAN[J]. College of Electronic Engineering, Naval University of Engineering, 2023, 77(2): 1985-2007.
- [24] WANG Y T, YANG L, SONG X, et al. A multi-feature ensemble learning classification method for ship classification with space-based AIS data [J]. Applied Sciences, 2021, 11(21):10336-10336.
- [25] ZHANG Y, YUAN Y, FENG Y, et al. Hierarchical and robust convolutional neural network for very high-resolution remote sensing object detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(8):5535-5548.
- [26] 王伟.基于遥感图像的舰船目标检测方法综述[J]. 电讯技术, 2020, 60(9):1126-1132.
WANG W. Overview of ship detection technology based on remote sensing images[J]. Telecommunication Engineering, 2020, 60(9): 1126-1132.

作者简介

曾富强,硕士研究生,主要研究方向为计算机视觉、深度学习。

E-mail:221112201127@stu.just.edu.cn

张贞凯(通信作者),教授,博士,主要研究方向为雷达信号处理、深度学习等。

E-mail:zhangzhenkai@just.edu.cn

方梦瑶,硕士研究生,主要研究方向为目标识别、深度学习。