

基于多尺度卷积神经网络的自适应熵加权决策融合船舶图像分类方法

任永梅^{①②} 杨 杰^{*①} 郭志强^① 曹 辉^①

^①(武汉理工大学信息工程学院宽带无线通信与传感器网络湖北省重点实验室 武汉 430070)

^②(湖南工学院电气与信息工程学院 衡阳 421002)

摘 要: 针对单一尺度卷积神经网络(CNN)对船舶图像分类的局限性, 该文提出一种多尺度CNN自适应熵加权决策融合方法用于船舶图像分类。首先使用多尺度CNN提取不同尺寸的船舶图像的多尺度特征, 并训练得到不同子网络的最优模型; 接着利用测试集船舶图像在最优模型上测试, 得到多尺度CNN的Softmax函数输出的概率值, 并计算得到信息熵, 进而实现对不同输入船舶图像赋予自适应的融合权重; 最后对不同子网络的Softmax函数输出概率值进行自适应熵加权决策融合实现船舶图像的最终分类。在VAIS数据集和自建数据集上分别进行了实验, 提出的方法的分类准确率分别达到了95.07%和97.50%, 实验结果表明, 与单一尺度CNN分类方法以及其他较新方法相比, 所提方法具有更优的分类性能。

关键词: 图像处理; 船舶图像分类; 多尺度卷积神经网络; 熵; 决策融合

中图分类号: TN911.73; TP391.4

文献标识码: A

文章编号: 1009-5896(2021)05-1424-08

DOI: 10.11999/JEIT200102

Self-adaptive Entropy Weighted Decision Fusion Method for Ship Image Classification Based on Multi-scale Convolutional Neural Network

REN Yongmei^{①②} YANG Jie^{*①} GUO Zhiqiang^① CAO Hui^①

^①(Hubei Key Laboratory of Broadband Wireless Communication and Sensor Networks, School of Information Engineering, Wuhan University of Technology, Wuhan 430070, China)

^②(School of Electrical and Information Engineering, Hunan Institute of Technology, Hengyang 421002, China)

Abstract: Considering the limitation of single scale Convolutional Neural Network (CNN) for ship image classification, a self-adaptive entropy weighted decision fusion method for ship image classification based on multi-scale CNN is proposed. Firstly, the multi-scale CNN is used to extract the multi-scale features of ship image with different sizes, and the optimum models of different sub-networks are trained. Then, the ship images of test set are tested on the optimum models, and the probability value that is output by Softmax function of multi-scale CNN is obtained, which is used to calculate the information entropy so as to realize the adaptive weight assigned to different input ship images. Finally, self-adaptive entropy weighted decision fusion is carried out for the probability value that is output by Softmax function of different sub-networks to realize the final ship image classification. Experiments perform on VAIS (Visible And Infrared Spectrums) and self-built datasets respectively, and the proposed method achieves average accuracy of 95.07% and 97.50% on these datasets respectively. The experimental results show that the proposed method has better classification performance than those of the single scale CNN classification method and other state-of-the-art methods.

Key words: Image processing; Ship image classification; Multi-scale Convolutional Neural Network (CNN); Entropy; Decision fusion

收稿日期: 2020-02-11; 改回日期: 2020-10-28; 网络出版: 2020-11-16

*通信作者: 杨杰 jieyang@whut.edu.cn

基金项目: 国家自然科学基金 (51879211), 国家重点研发计划(2020YFB1710800), 湖南省教育厅科学研究项目(18C0900)

Foundation Items: The National Natural Science Foundation of China (51879211), The National Key Research and Development Program of China (2020YFB1710800), The Scientific Research Project of the Hunan Provincial Education Department (18C0900)

1 引言

船舶图像分类是海上安全和交通管理中的一个重要问题,它广泛应用于民用和军事领域^[1,2]。实际场景中的船舶图像不仅背景复杂,不同的光照强度、视角等也会对分类性能产生影响,因此船舶图像分类已经成为模式识别领域的研究热点之一。

现有船舶图像分类方法主要分为基于传统特征的分类方法和基于卷积神经网络的分类方法。传统特征主要有方向梯度直方图(Histogram of Oriented Gradients, HOG)^[3]、尺度不变特征变换(Scale-Invariant Feature Transform, SIFT)^[4]以及局部二值模式(Local Binary Pattern, LBP)^[5]等。传统特征是目标的底层视觉特征,在表达图像的能力上有较大局限性,并且需要依赖专家知识,通用性差。近年来,随着深度学习技术的快速发展,卷积神经网络(Convolutional Neural Network, CNN)成为许多学者的研究热点,并成功运用在图像分类^[6]、目标检测^[7]以及行人检测^[8]等领域。文献^[9]提出AlexNet和极限学习机结合的分类方法,在Fleetmoom船舶图像库上的分类准确率达到94%。文献^[10]提取多个船舶分类特征组成特征向量集,并将特征向量集作为深度学习算法的输入,建立船舶分类模型。文献^[11]提出一种集成多特征的卷积神经网络(ME-CNN)对光学遥感船舶图像进行分类。文献^[12]提出用多分辨率CNN对TerraSAR-X图像进行船舶分类,不同的通道连接不同分辨率的原始图像,所有通道具有固定的2.5 m的像素空间和128×128的图像尺寸。但图像分辨率的变化是如何影响CNN内部激活的,还需要进行更多的实验。文献^[13]提出“中心—扩散池化”CNN和“前景—扩散池化”CNN,对可视化船舶图像进行分类,在其自建数据集上的分类准确率达到92.8%。

上述研究中,都是利用单一尺度的CNN进行船舶图像分类,对不同种类的样本的分类具有不确定性,分类准确率还需进一步提高。近年来,决策融合技术受到模式识别领域的学者的关注,其依据各个数据源的单独决策结果在融合中心进行关联处理,做出最终的决策,使得融合方法比单个分类器在决策时出错更少^[14]。因此,本文针对单一尺度CNN在船舶图像分类中的精度需要进一步提高的问题,提出一种多尺度CNN的自适应熵加权决策融合船舶图像分类方法。在该方法中,先使用3个不同的子网络提取多尺度下的船舶图像特征,并利用Softmax函数输出的概率值计算信息熵,保证对不同输入船舶图像赋予自适应的权重;最后对3个不同子网络的Softmax输出值进行自适应熵加权决

策融合处理以实现船舶图像的高精度分类,同时确保提高模型的稳定性和鲁棒性。通过与其他方法的对比,发现本文方法能取得良好的分类效果。

2 多尺度CNN

卷积神经网络(CNN)是一个多层感知机,使用局部连接和权值共享方式,可以降低网络训练参数的数量。单一尺度的CNN在执行图像分类任务时需要输入固定尺寸的图像^[15],而实际环境中的图像大小往往是多样化的。虽然可以经过缩放等预处理步骤将图像尺寸调整为CNN需要的大小,但这会影响图像的分类准确率。在卷积过程中,网络感受野在不同尺寸的图像块上的占比不同,大尺寸的图像块进行卷积操作后得到的特征信息更丰富,也能更好地反映图像的局部特征,小尺寸的图像块进行卷积操作后得到的特征则能更好地反映图像的全局特征^[16]。因此本文将使用多尺度CNN对不同尺寸输入船舶图像进行特征提取,可以得到更多的图像特征,并通过Softmax函数获得不同尺度船舶图像的输出概率值。

2.1 多尺度CNN总体结构设计

本文选择3个并行的子网络组成如图1所示的多尺度CNN,图1中分别使用文献^[17]中提出的卷积神经网络,命名为CNN1、文献^[12]中的卷积神经网络,命名为CNN2以及AlexNet^[6](命名为CNN3)来提取船舶图像的多尺度特征。因为上述3个网络的输入图像尺寸不同,分别覆盖了小尺寸、中尺寸和大尺寸图像,网络深度不同,同时在单一尺度输入样本情况下可以提取到比较有用的特征。另外与其他网络模型如ResNet-34、GoogLeNet、VGG-16和VGG-19等深层网络相比,上述网络具有层数少、参数量少等优点。

(1) CNN1: CNN1的输入图像尺寸要求为56×56的船舶图像,有4个卷积层,2个池化层,2个全连接层,1个Softmax层,卷积层步长为1,池化层步长为2。网络结构和具体参数如图2所示。卷积层和全连接层使用的激活函数为修正线性单元(Rectified Linear Units, ReLU)函数,相比Sigmoid和tanh等激活函数,ReLU函数具有能够加速




图1 多尺度卷积神经网络

收敛、缓解过拟合等特点。图2中Conv1-32@ (5×5) 表示第1个卷积层的滤波器个数为32, 卷积核尺寸为 5×5 , Max Pooling1(2×2)表示第1个最大池化层的卷积核大小为 2×2 , FC1-384表示第1个全连接层将第4个卷积层的特征映射连接得到384个 1×1 维的神经元, Softmax-6(4)表示利用Softmax函数得到6个或4个输出决策类别, 6和4分别对应文中的两个数据集的船舶类型数目(见5.1节)。

(2) CNN2: CNN2的输入图像尺寸要求为 128×128 的船舶图像, 有4个卷积层, 4个池化层, 1个全连接层, 1个Softmax层, 卷积层步长为1, 池化层步长为2。网络结构和具体参数如图3所示。全连接层使用的激活函数为Sigmoid函数。

(3) CNN3: AlexNet在本文中用CNN3表示, CNN3网络的输入图像尺寸要求为 227×227 的船舶图像, 有5个卷积层, 3个池化层, 2个全连接层, 1个Softmax层。卷积层和全连接层使用的激活函数为ReLU函数。

可以看出以上3个子网络在最后一个全连接层均使用Softmax函数来进行分类, Softmax函数的输出为概率型, 表示输入样本属于每一类的概率。

3 自适应熵加权决策融合算法

最大输出概率决策融合方法是一种最简单的决策融合方法, 该方法通过对不同子分类器输出的概率计算出最大值的方式来求出输入图像最终的所属类别。如果每个分类器的输出概率的最大值出现在同一类别上, 决策结果就没有变化, 然而, 随着概率的变化, 决策的可能性有很大的不同。这种方法

没有涉及各个分类器在决策融合时所占的权重, 然而每个分类器所占的融合权重决定着决策融合的分类效果。不同尺寸的图像经过多尺度CNN提取的特征不同, 并且样本具有一定的随机性, 所以需要制定一个适合船舶图像的决策方法, 进而获得最优的分类性能。本文使用自适应熵加权决策融合方法为不同输入船舶图像赋予不同融合权重, 进一步提高算法的分类准确率, 同时确保模型具有更好的稳定性和鲁棒性。本文的多尺度CNN是由3个CNN组成, 因此1个输入船舶图像的分类结果就由3个Softmax函数的输出概率值进行自适应熵加权决策融合得到最终分类结果。具体的自适应熵加权决策融合算法如下。

采用多尺度CNN的3个Softmax函数并行输出时, 可以得到每个输入船舶图像的概率输出矩阵为

$$\mathbf{P}(x) = \begin{bmatrix} p_{11}(x) & p_{12}(x) & \cdots & p_{1n}(x) \\ p_{21}(x) & p_{22}(x) & \cdots & p_{2n}(x) \\ p_{31}(x) & p_{32}(x) & \cdots & p_{3n}(x) \end{bmatrix}_{3 \times n} \quad (1)$$

其中, 每一行代表1个子网络的Softmax函数对输入样本 x 的概率输出值, n 表示船舶种类数, 每一行概率最大的列标即为每个子网络的Softmax函数对该样本的预测类别。输入样本 x 属于每一类的概率值的特点将对分类准确率产生影响, 具体为, 如果各个概率值的差别越小, 分类的不确定性就越大; 如果最大的概率值与其他概率值的差别越大, 则分类结果越可靠。因此, 本文引入如式(2)所示的信息熵^[18] $H_i(x)$ 来表征输入样本 x 被第 i 个子网络的Softmax函数分类的不确定性。




图2 CNN1网络结构和参数




图3 CNN2网络结构和参数

$$H_i(x) = - \sum_{j=1}^n p_{ij}(x) \log_2 p_{ij}(x), \quad i = 1, 2, 3 \quad (2)$$

其中, $p_{ij}(x)$ 表示第*i*个子网络的Softmax函数将输入样本*x*判为属于*j*类的概率, 如果某个子网络的Softmax函数的信息熵的值越大, 分类的不确定性就越高, 则该网络的Softmax函数对输入样本*x*的分类能力就差, 该网络的Softmax函数对输入样本*x*的融合权重就越小, 反之亦然。因此, 多尺度CNN的Softmax函数的自适应的融合权重计算公式为

$$\omega_i = \frac{\exp(-H_i(x))}{\sum_{p=1}^3 \exp(-H_p(x))}, \quad i = 1, 2, 3 \quad (3)$$

得到融合权重后, 对式(1)所示的概率输出矩阵 $\mathbf{P}(x)$ 的每一行乘以权重, 得到新的概率输出矩阵 $\mathbf{P}'(x)$

$$\mathbf{P}'(x) = \begin{bmatrix} \omega_1 p_{11}(x) & \omega_1 p_{12}(x) & \cdots & \omega_1 p_{1n}(x) \\ \omega_2 p_{21}(x) & \omega_2 p_{22}(x) & \cdots & \omega_2 p_{2n}(x) \\ \omega_3 p_{31}(x) & \omega_3 p_{32}(x) & \cdots & \omega_3 p_{3n}(x) \end{bmatrix}_{3 \times n} \quad (4)$$

将 $\mathbf{P}'(x)$ 按列加权求和, 则加权求和后的最大值的标签就是决策融合的结果, 如式(5)所示

$$\text{label}(x) = \arg \max_{j=1,2,\dots,n} \left[\sum_{i=1}^3 \omega_i p_{ij}(x) \right] \quad (5)$$

自适应熵加权决策融合算法充分考虑了不同子网络的Softmax函数对相同的输入船舶图像的分类性能不同以及同一个子网络的Softmax函数对不同的输入船舶图像的分类性能也有差异的特性, 自适应地对不同的输入船舶图像赋予更为合理的融合权重, 同时解决了单一尺度CNN由于Softmax函数输出的概率值过于接近而造成的误分类问题。

4 基于多尺度CNN的自适应熵加权决策融合船舶图像分类方法

本文提出的方法主要包括训练过程和自适应熵加权决策融合测试过程。具体实现如下:

(1) 训练过程: 使用“从头开始训练”(training CNN network from scratch)的方法训练3个子网络, 训练的目的在于寻找最优参数, 以最小化损失函数。数据集的训练样本(见5.1节)经过预处理后分别送入3个CNN中进行特征提取, 利用Softmax函数得到船舶图像的预测类别, 计算预测类别标签和真实类别标签之间的误差, 通过反向传播过程调整权值和偏差, 使误差最小化, 得到不同子网络的最优模型并进行保存。

(2) 自适应熵加权决策融合测试过程: 测试样本预处理后, 输入到多尺度CNN中提取特征, 分别调用训练好的3个最优模型进行测试, 得到Softmax输出的概率值, 最后利用自适应熵加权决策融合算法得到最终分类结果。本文方法的总体流程图如图4所示。

本文采用双3次插值方法调整每幅图像的大小。对于CNN1, CNN2和CNN3, 将图像分别预处理为 64×64 像素、 147×147 像素和 256×256 像素, 将输入到以上3个子网络的训练样本分别随机裁剪为 56×56 像素、 128×128 像素和 227×227 像素; 测试集样本仅作中心裁剪。对训练样本进行随机裁剪, 不仅能够增加训练数据, 保证样本的随机性, 避免过拟合, 而且保留了图像的重要信息。同时, 我们也使用了随机水平翻转等数据增强方法, 进一步提升模型的鲁棒性和泛化能力。

5 实验结果及分析

5.1 实验仿真环境及数据集

实验仿真环境为Inter(R) Core(TM) i9-7980XE@2.6 GHz, 内存32 GB, 显卡NVIDIA TITAN Xp Pascal, 采用Python3.5, Pytorch框架编程实现所有实验。

本文使用的第1个数据集是VAIS数据集^[19], 包括2865幅图像(1623幅可视化图像, 1242幅红外图像)。该数据集包含6种粗粒度类别, 分别为mediums “other” ships, merchant ships, medium passen-




图4 本文方法的总体流程图

ger ships, sailing ships, small boats, tugboats。本文仅选择可视化图像, 随机选取共873幅为训练图像, 剩余750幅为测试图像, 训练集和测试集样本数量如表1所示。第2个数据集是自建数据集^[7], 包括9000幅船舶图像。该数据集包含4种类别, 分别为散货船、集装箱船、客船以及帆船。从数据集中随机选取共7201幅为训练图像, 剩余1799幅为测试图像, 训练集和测试集样本数量如表2所示。

5.2 评价指标

本文使用分类准确率(Accuracy, Acc)、误分类样本数、每幅图的特征提取时间以及混淆矩阵来评价船舶图像分类效果。分类准确率是分类正确的样本数占样本总数的比例, 如式(6)所示

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (6)$$

其中, TP为真正例, FP为假正例, TN为真反例, FN为假反例。

误分类样本数是总样本数与错误率($1 - \text{Acc}$)的乘积。混淆矩阵表示分类器处理多分类问题时造成的混淆情况, 横轴表示预测类别, 纵轴表示真实类别, 对角线上的值表示每类图像被正确分类的个数。

5.3 实验结果分析

为验证本文方法的有效性, 将本文方法与单一尺度CNN分类方法以及近几年代表性的几种分类方法在相同实验条件下作了比较。本文使用随机梯度下降算法(SGD)最小化交叉熵损失函数, 迭代更新卷积神经网络权重。不同子网络训练得到最优模型的参数设置如下:

表1 VAIS数据集的训练样本和测试样本数量

序号	类名	训练	测试
1	medium-other	99	86
2	merchant	103	71
3	medium-passenger	78	62
4	sailing	214	198
5	small	342	313
6	tug	37	20
	合计	873	750

表2 自建数据集的训练样本和测试样本数量

序号	类名	训练	测试
1	散货船	1385	346
2	集装箱船	2381	595
3	客船	1632	408
4	帆船	1803	450
	合计	7201	1799

对于文中使用的两个数据集, CNN1, CNN2和CNN3的学习率均为0.001, 动量参数均为0.9, 批处理样本数量(batch size)均为32, 丢弃率(dropout)均为0.5。不同的是对于VAIS数据集, CNN1的权重衰减系数取0.0005, 学习周期为269。CNN2和CNN3的权重衰减系数均为0.0001, 学习周期分别为572和276。对于自建数据集, CNN1的权重衰减系数取0.0005, 学习周期为97。CNN2和CNN3的权重衰减系数均为0.0001, 学习周期分别为70和30。

5.3.1 与单一尺度CNN分类方法的对比

表3和表4为单一尺度CNN分类方法及本文方法在两个数据集上的分类准确率和对于每幅图像用于特征提取的平均时间消耗。可以看出, 本文方法的分类准确率最高, 因为多尺度CNN提取了更丰富的船舶图像特征并且决策策略考虑了各个子网络的Softmax函数针对不同输入样本分类性能不同的特性, 确定了更为合理的融合权重。由于进行了决策融合, 所以本文方法对于每幅图像用于特征提取的平均时间消耗比单一尺度CNN分类方法的特征提取时间稍高, 但0.391 ms和0.396 ms的时间消耗也是比较快的, 在可接受范围内, 实际应用中也不会产生很大的影响。

为了进一步验证本文方法的性能, 表5和表6列出了单一尺度CNN分类方法及本文方法在两个数据集上对每一类的分类准确率。可以看出本文方法比单一尺度CNN分类方法表现出更好的分类性能, 对于VAIS数据集, 本文方法对于除medium-passenger之外的其余5类船舶图像的分类准确率都最高, 对medium-passenger的分类准确率比CNN2和CNN3方法对medium-passenger的分类准确率有提

表3 不同方法在VAIS数据集上的分类准确率和对于每幅图像用于特征提取的平均时间消耗

方法	分类准确率(%)	特征提取时间(ms)
CNN1	92.13	0.104
CNN2	90.93	0.045
CNN3	90.67	0.092
本文方法	95.07	0.391

表4 不同方法在自建数据集上的分类准确率和对于每幅图像用于特征提取的平均时间消耗

方法	分类准确率(%)	特征提取时间(ms)
CNN1	96.50	0.047
CNN2	94.61	0.048
CNN3	96.16	0.071
本文方法	97.50	0.396

表5 不同方法在VAIS数据集上对每一类的分类准确率(%)

方法	类别					
	medium-other	merchant	medium-passenger	sailing	small	tug
CNN1	80.23	87.32	88.71	94.95	94.89	100.00
CNN2	83.72	87.32	70.96	93.94	95.85	90.00
CNN3	81.40	94.37	75.80	100.00	89.78	85.00
本文方法	87.21	94.37	80.65	100.00	96.81	100.00

表6 不同方法在自建数据集上对每一类的分类准确率(%)

方法	类别			
	散货船	集装箱船	客船	帆船
CNN1	95.95	95.97	96.56	97.56
CNN2	89.60	96.30	96.81	94.22
CNN3	94.22	97.48	93.14	98.67
本文方法	96.53	97.82	96.57	98.67

升,但低于CNN1方法对medium-passenger的分类准确率。原因是CNN2和CNN3方法对于medium-passenger的分类准确率与它们对其他5类的分类准确率相比是最低的,并且它们对于medium-passenger的分类准确率与CNN1方法对于medium-passenger的分类准确率相差较多;而对其他5类的分类准确率都有提高,说明本文方法可以更好地解决单一尺度CNN网络由于Softmax函数输出的概率值过于接近而造成的误分类问题。对于自建数据集,本文方法对散货船、集装箱船的分类准确率提高最多。

5.3.2 与近几年代表性的分类方法的对比

为了进一步验证本文方法的优势,将本文方法与近几年代表性的分类方法进行了对比,结果见表7和表8。从表7和表8可以看出,与其他几种方法相比,本文方法的分类准确率最高,误分类样本数最少,进一步说明本文方法充分权衡了不同子网络的分类性能和输入船舶图像的随机性,为输入船舶图像分配了合理的融合权重,确保了多尺度输入船舶图像的分类鲁棒性,在船舶图像分类方面具有显著的优势。

5.3.3 本文方法的分类结果的混淆矩阵

图5为本文方法在VAIS数据集和自建数据集上的分类结果的混淆矩阵。图5(a)中:0为medium-other;1为merchant;2为medium-passenger;3为sailing;4为small;5为tug。图5(b)中:0为散货船;1为集装箱船;2为客船;3为帆船。从图5(a)可以看出,混淆主要发生在第0类和第4类之间,第2类和第3类之间以及第2类和第4类之间。VAIS数据集中的medium-other船舶包括fishing, medium other;

表7 本文方法与其他方法在VAIS数据集上的分类准确率和误分类样本数

方法	分类准确率(%)	误分类样本数
文献[3]方法	87.47	94
文献[20]方法	90.27	73
文献[13]方法	84.80	114
文献[12]方法	90.93	68
文献[21]方法	86.93	98
文献[22]方法	90.00	75
最大输出概率决策融合法	94.80	39
多数投票法	94.00	45
本文方法	95.07	37

表8 本文方法与其他方法在自建数据集上的分类准确率和误分类样本数

方法	分类准确率(%)	误分类样本数
文献[3]方法	89.16	195
文献[20]方法	93.72	113
文献[12]方法	94.61	97
文献[21]方法	92.94	127
文献[22]方法	96.22	68
文献[13]方法	94.11	106
最大输出概率决策融合法	97.11	52
多数投票法	96.83	57
本文方法	97.50	45

small船舶包括speedboat, jetski, smaller pleasure, larger pleasure。因此,一些small和medium-other有很高的相似性。数据集中的有些medium-passenger和sailing的图像是模糊的,一些medium-passenger和small也有相似性。因此决策融合后有些medium-passenger仍被错分为sailing和small。从图5(b)可以看出,混淆主要发生在第0类和第1类之间,第1类和第2类之间,因为散货船和集装箱船的船长很接近,有的散货船和集装箱船类似。另外,有些集装箱船和客船从外观上远距离看比较类似。




图5 本文方法的分类结果的混淆矩阵。

6 结束语

本文提出了一种基于多尺度CNN的自适应熵加权决策融合船舶图像分类方法。该方法首先使用3个不同的CNN得到输入样本的Softmax函数的输出概率值,然后使用自适应熵加权决策融合方法得到最终的分类结果。自适应熵加权决策融合可以综合考虑不同子网络的Softmax函数对输入样本的分类结果的不同,自适应地确定了比较合理的融合权重。为了验证本文方法的有效性,在VAIS数据集和自建的船舶图像数据集上分别进行了实验。实验结果表明,与单一尺度CNN分类方法以及近几年代表性的方法相比,本文方法的分类性能都有较大提升。在以后的研究中,可以考虑研究进一步优化分类模型等方面的工作。

参考文献

- [1] ZHANG Erhu, WANG Kelu, and LIN Guangfeng. Classification of marine vessels with multi-feature structure fusion[J]. *Applied Sciences*, 2019, 9(10): 2153. doi: [10.3390/app9102153](https://doi.org/10.3390/app9102153).
- [2] DONG Chao, LIU Jinghong, and XU Fang. Ship detection in optical remote sensing images based on saliency and a rotation-invariant descriptor[J]. *Remote Sensing*, 2018, 10(3): 400. doi: [10.3390/rs10030400](https://doi.org/10.3390/rs10030400).
- [3] 吴映铮, 杨柳涛. 基于HOG和SVM的船舶图像分类算法[J]. 上海船舶运输科学研究所学报, 2019, 42(1): 58–64. WU Yingzheng and YANG Liutao. Ship image classification by combined use of HOG and SVM[J]. *Journal of Shanghai Ship and Shipping Research Institute*, 2019, 42(1): 58–64.
- [4] PARAMESWARAN S and RAINEY K. Vessel classification in overhead satellite imagery using weighted “bag of visual words” [C]. SPIE 9476, Automatic Target Recognition XXV, Baltimore, USA, 2015: 947609. doi: [10.1117/12.2177779](https://doi.org/10.1117/12.2177779).
- [5] ARGUEDAS V F. Texture-based vessel classifier for electro-optical satellite imagery[C]. 2015 IEEE International Conference on Image Processing, Quebec City, Canada, 2015: 3866–3870. doi: [10.1109/ICIP.2015.7351529](https://doi.org/10.1109/ICIP.2015.7351529).
- [6] 王鑫, 李可, 宁晨, 等. 基于深度卷积神经网络和多核学习的遥感图像分类方法[J]. 电子与信息学报, 2019, 41(5): 1098–1105. doi: [10.11999/JEIT180628](https://doi.org/10.11999/JEIT180628). WANG Xin, LI Ke, NING Chen, et al. Remote sensing image classification method based on deep convolution neural network and multi-kernel learning[J]. *Journal of Electronics & Information Technology*, 2019, 41(5): 1098–1105. doi: [10.11999/JEIT180628](https://doi.org/10.11999/JEIT180628).
- [7] 李健伟, 曲长文, 彭书娟, 等. 基于生成对抗网络和线上难例挖掘的SAR图像舰船目标检测[J]. 电子与信息学报, 2019, 41(1): 143–149. doi: [10.11999/JEIT180050](https://doi.org/10.11999/JEIT180050). LI Jianwei, QU Changwen, PENG Shujuan, et al. Ship detection in SAR images based on generative adversarial network and online hard examples mining[J]. *Journal of Electronics & Information Technology*, 2019, 41(1): 143–149. doi: [10.11999/JEIT180050](https://doi.org/10.11999/JEIT180050).
- [8] CHEN Yunfan, XIE Han, and SHIN H. Multi-layer fusion techniques using a CNN for multispectral pedestrian detection[J]. *IET Computer Vision*, 2018, 12(8): 1179–1187. doi: [10.1049/iet-cvi.2018.5315](https://doi.org/10.1049/iet-cvi.2018.5315).
- [9] 闫河, 王鹏, 董莺艳, 等. 一种CNN与ELM相结合的船舶分类识别方法[J]. 重庆理工大学学报: 自然科学, 2019, 33(1): 53–57. doi: [10.3969/j.issn.1674-8425\(z\).2019.01.008](https://doi.org/10.3969/j.issn.1674-8425(z).2019.01.008). YAN He, WANG Peng, DONG Yingyan, et al. A classification identification method of ships combining CNN and ELM[J]. *Journal of Chongqing Institute of Technology: Natural Science*, 2019, 33(1): 53–57. doi: [10.3969/j.issn.1674-8425\(z\).2019.01.008](https://doi.org/10.3969/j.issn.1674-8425(z).2019.01.008).
- [10] 陈兴伟. 深度学习船舶分类技术研究[J]. 舰船科学技术, 2019, 41(7A): 142–144. doi: [10.3404/j.issn.1672-7649.2019.7A.048](https://doi.org/10.3404/j.issn.1672-7649.2019.7A.048). CHEN Xingwei. Research on ship classification technology based on deep learning[J]. *Ship Science and Technology*, 2019, 41(7A): 142–144. doi: [10.3404/j.issn.1672-7649.2019.7A.048](https://doi.org/10.3404/j.issn.1672-7649.2019.7A.048).

- [11] SHI Qiaoqiao, LI Wei, TAO Ran, *et al.* Ship classification based on multifeature ensemble with convolutional neural network[J]. *Remote Sensing*, 2019, 11(4): 419. doi: [10.3390/rs11040419](https://doi.org/10.3390/rs11040419).
- [12] BENTES C, VELOTTO D, and TINGS B. Ship classification in TerraSAR-X images with convolutional neural networks[J]. *IEEE Journal of Oceanic Engineering*, 2018, 43(1): 258–266. doi: [10.1109/JOE.2017.2767106](https://doi.org/10.1109/JOE.2017.2767106).
- [13] 杨亚东, 王晓峰, 潘静静. 改进CNN及其在船舶识别中的应用[J]. 计算机工程与设计, 2018, 39(10): 3228–3233. doi: [10.16208/j.issn1000-7024.2018.10.039](https://doi.org/10.16208/j.issn1000-7024.2018.10.039).
YANG Yadong, WANG Xiaofeng, and PAN Jingjing. Improved CNN and its application in ship identification[J]. *Computer Engineering and Design*, 2018, 39(10): 3228–3233. doi: [10.16208/j.issn1000-7024.2018.10.039](https://doi.org/10.16208/j.issn1000-7024.2018.10.039).
- [14] LI Xiaobin, JIANG Bitao, SUN Tong, *et al.* Remote sensing scene classification based on decision-level fusion[C]. 2018 IEEE 4th Information Technology and Mechatronics Engineering Conference, Chongqing, China, 2018: 393–397. doi: [10.1109/ITOEC.2018.8740526](https://doi.org/10.1109/ITOEC.2018.8740526).
- [15] GENG Jie, JIANG Wen, and DENG Xinyang. Multi-scale deep feature learning network with bilateral filtering for SAR image classification[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 167: 201–213. doi: [10.1016/j.isprsjprs.2020.07.007](https://doi.org/10.1016/j.isprsjprs.2020.07.007).
- [16] 李凯, 韩冰, 张景滔. 基于条件随机场与多尺度卷积神经网络的交通标志检测与识别[J]. 计算机应用, 2018, 38(S2): 270–275.
LI Kai, HAN Bing, and ZHANG Jingtao. Traffic sign detection and recognition based on conditional random field and multi-scale convolutional neural network[J]. *Journal of Computer Applications*, 2018, 38(S2): 270–275.
- [17] REN Yongmei, YANG Jie, ZHANG Qingnian, *et al.* Multi-feature fusion with convolutional neural network for ship classification in optical images[J]. *Applied Sciences*, 2019, 9(20): 4209. doi: [10.3390/app9204209](https://doi.org/10.3390/app9204209).
- [18] CHEN Wangcai, LIU Wenbo and LI Kaiyu. Rail crack recognition based on adaptive weighting multi-classifier fusion decision[J]. *Measurement*, 2018, 123: 102–114. doi: [10.1016/j.measurement.2018.03.059](https://doi.org/10.1016/j.measurement.2018.03.059).
- [19] ZHANG M M, CHOI J, DANILIDIS K, *et al.* VAIS: A dataset for recognizing maritime imagery in the visible and infrared spectrums[C]. The 2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Boston, USA, 2015: 10–16. doi: [10.1109/CVPRW.2015.7301291](https://doi.org/10.1109/CVPRW.2015.7301291).
- [20] DING Jun, CHEN Bo, LIU Hongwei, *et al.* Convolutional neural network with data augmentation for SAR target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 364–368. doi: [10.1109/LGRS.2015.2513754](https://doi.org/10.1109/LGRS.2015.2513754).
- [21] RAINEY K, REEDER J D, and CORELLI A G. Convolution neural networks for ship type recognition[C]. SPIE 9844, Automatic Target Recognition XXVI, Baltimore, USA, 2016: 984409. doi: [10.1117/12.2229366](https://doi.org/10.1117/12.2229366).
- [22] LI Zhenzhen, ZHAO Baojun, TANG Linbo, *et al.* Ship classification based on convolutional neural networks[J]. *The Journal of Engineering*, 2019, 2019(21): 7343–7346. doi: [10.1049/joe.2019.0422](https://doi.org/10.1049/joe.2019.0422).
- 任永梅: 女, 1988年生, 博士生, 研究方向为图像处理与模式识别。
杨 杰: 女, 1960年生, 教授, 研究方向为图像处理与模式识别。
郭志强: 男, 1976年生, 教授, 研究方向为图像处理与模式识别。
曹 辉: 男, 1986年生, 讲师, 研究方向为数字信号的智能处理。
- 责任编辑: 马秀强