

DOI: 10.19650/j.cnki.cjsi.J2108456

全局注意力关系网络的小样本船舶识别*

孟浩^{1,2}, 田洋^{1,2}, 孙宇婷^{1,2}, 李涛^{1,2}

(1. 哈尔滨工程大学智能科学与工程学院 哈尔滨 150001; 2. 哈尔滨工程大学船海装备智能化技术与应用教育部重点实验室 哈尔滨 150001)

摘要:实际场景中采集的船舶目标类别样本数量不均衡,模型训练易导致过拟合。传统迁移学习的数据集划分存在类别交叉,造成未标注新类别识别精度低。为解决上述问题,提出了一种跨目标通用全局注意力机制与关系度量网络融合的小样本船舶识别算法。该方法通过在关系网络中引入全局注意力机制,利用关系网络提取到的原始特征,经过全局注意力机制平滑不均衡类别间的目标特征,并与关系网络提取的原始特征融合后进行特征距离度量。该方法增强了全局特征之间的一致性,有利于学习不变的目标特征,提升少样本少标签的船舶目标识别性能,解决了训练过程中类别不均衡导致的过拟合问题。利用自己采集制作的船舶数据集对本文方法进行测试实验,识别精度提高了5.6% (5-shot)、3.2% (1-shot),减小了不均衡类别对模型目标识别造成的影响,增强了模型的鲁棒性。

关键词:小样本;船舶识别;全局注意力;关系度量网络

中图分类号: TH89 TP391.4 **文献标识码:** A **国家标准学科分类代码:** 510.8060

Few shot ship recognition based on universal attention relationnet

Meng Hao^{1,2}, Tian Yang^{1,2}, Sun Yuting^{1,2}, Li Tao^{1,2}

(1. School of intelligent science and Engineering, Harbin Engineering University, Harbin 150001, China;
2. Key laboratory of Intelligent Technology and Application of Marine Equipment, Harbin Engineering University, Ministry of Education, Harbin 150001, China)

Abstract: The sample number of ship target categories collected in actual scenes is not balanced, and the model training easily leads to be overfitting. The data set of the traditional transfer learning is divided into categories, which results in low recognition accuracy of unlabeled new categories. To solve the above problems, a small sample ship identification algorithm based on the fusion of the cross-target universal global attention mechanism and the relationship measurement network is proposed. This method introduces the universal attention mechanism into the relation network, uses the original features extracted by relation network, and smooths the target features between imbalanced categories through the universal attention mechanism, and compares them with the original features extracted by the relation network. After feature fusion, feature distance measurement is performed. This method enhances the consistency among universal features, which is conducive to learning invariant target features and improve the performance of ship recognition with few samples and few labels. In this way, the overfitting problem caused by imbalance of categories in the training process could be solved. Using the ship data set collected and produced by ourselves to test the proposed method, the recognition accuracy is improved 5.6% (5-shot) and 3.2% (1-shot). The impact of imbalanced category on the model ship recognition is reduced, and the robust of the model is enhanced.

Keywords: few shot; ship recognition; universal attention; relation network

收稿日期:2021-08-22 Received Date: 2021-08-22

* 基金项目:船舶态势智能感知系统研制(MC-201920-X01)项目资助

0 引 言

随着航运业发展,船舶交通事故也频繁发生。船舶目标识别成为了海上船舶营救,海事管理,港口动态监控等安防领域应用的重要技术之一。传统的船舶目标识别通过迁移学习^[1-4],将模型最优参数迁移到新模型上进行模型参数微调,以完成模型预测目标泛化能力最大化。这些迁移学习和模型微调结合的训练方式,核心内容是目标类别样本量均衡,样本全标注。而小样本中元学习^[5-6]提出的弱标注或无标注模型训练,不需要迁移大量数据权重参数作为模型训练基础,极大减小了因模型训练的参数数量以及样本标注量少而造成的模型训练过程中的过拟合现象和类别不均衡造成目标识别精度低等问题。然而,由于海况情况复杂,海浪、天气等一系列干扰因素,造成采集图像噪声大,样本数量少,因此,小样本船舶目标识别仍然是一个具有挑战性的问题。

目前,小样本目标识别的方法主要有两种:有监督情节式学习和无监督表征式学习。有监督情节式学习^[7-10]是通过每个任务支持集 (support) 的少标签样本信息与查询集 (query) 样本进行特征比较,度量 support 和 query 中样本之间的距离,通过“参数更新”和“学习比较”,使学习适应新任务,旨在学习基于特征空间和分类识别的良好特征。无监督表征式学习^[11-13],在训练阶段利用无标注的数据进行学习,元测试阶段,有监督和无监督的设置相同,在支持集和查询集中均有部分辅助标注标签。为了进一步减少整体的标签学习过程,在元训练期间没有任何标签,降低数据的标签成本。除上述方法外,现在研究的表示学习与图神经网络(GNN)联系较为密切,大多数现有的图神经网络模型依赖于给定图的拓扑结构。在执行图卷积过程^[14-15]中,在给定的图形中直接从邻近聚合阶段特征,并堆叠多个 GNN 层以捕获远程节点的依赖性。

上述方法,模型在训练过程中着重于建立最近的、最新的小样本任务近邻分类器,使用特征嵌入学习和特征间距离度量。然而,船舶目标识别在复杂海况及干扰条件(天气、光照、图像采集传感器)较大的情况下,训练的模型无法适应每个类别的特征任务,从而限制了泛化性能。因此提出一种跨目标通用全局注意力机制(universal attention relationnet, UAN),该方法通过在关系网络(relation network, RN)^[16]中引入全局注意力机制,利用 RN 提取到的原始特征,经过全局注意力机制平滑不均衡类别间的目标特征,并与 RN 提取的原始特征融合后进行特征距离度量。旨在从丰富数量的样本中学习广义对象特征、基本对象类别和新类别中的少量样本信息,同时描述不变的对象特征并减轻不均衡类别的影响。提高模型新类别目标识别准确率,增强模型鲁棒性。

1 模型方法

1.1 关系度量网络的小样本船舶目标识别结构和原理

如图 1 所示,机器学习数据集训练划分为 3 个数据集,训练集 (train set), 验证集 (val set) 和测试集 (test set)。训练集和验证集共享相同的标签空间,该标签空间也与测试集标签空间相交。训练时在每次训练迭代中,通过从训练集和验证集中随机选取 mini-batch 张样本图像,来形成每个训练任务。预测船舶目标类型时,从测试集中随机选取 mini-batch 张样本图像,来形成测试任务。通过与目标类别标注标签比对,从而判别迁移学习或机器学习模型目标识别精度。整个训练和测试过程中标签空间共享,对于未标注或未共享标签空间的新类别,模型识别精度低,训练时也易导致过拟合。



图 1 机器学习数据集划分和元学习数据集划分

Fig. 1 Machine learning data set division and meta-learning data set division

小样本学习数据集训练采用元学习方法,数据集划分为 3 个数据集,训练集 (train set), 支持集 (support set) 和测试集 (test set)。支持集和测试集共享相同的标签空间,但是训练集具有自己的标签空间,该标签空间与支持/测试集不相交。训练时在每次训练迭代中,通过从训练集中随机选择 C 个类别(其中每个类别有 K 个标记样本)来形成每个训练任务,样本集合为 $S = \{(x_i, y_i)\}$, $m_i = 1, m = k \times C$, 其中 C 类样本其余部分为未标记的样本,用作查询集 $Q = \{(x_i, y_i)\}, n_{j=1}$ 。本文的实验设置了 $K = 1$ 和 $K = 5$ 两种情况。

如图 2 所示,模型 1-Shot 的关系网络(RN)由两个模块组成:特征提取嵌入模块 f_ϕ 和关系距离度量模块 g_ϕ , 通过查询集 Q 中的样本 x_j 和支持集 S 中的样本 x_i 馈入。特征提取嵌入模块采用 4 个 Conv Block 卷积块提取馈入的图像样本特征并输出 f_ϕ , 对于每个任务集中的支持集馈入 x_i 和查询集馈入 x_j 通过嵌入模块网络生成特征图

$f_\varphi(x_i)$ 和 $f_\varphi(x_j)$ 。将支持集和查询集生成的特征图 $f_\varphi(x_i)$ 和 $f_\varphi(x_j)$ 融合在一起,输出嵌入图像样本特征融合算子 $c(f_\varphi(x_i), f_\varphi(x_j))$ 。在模型中假定 $c(:, :)$ 是深度上的特征图的串联,支持集样本和查询集样本特征的融合被送到关系距离度量模块 g_ϕ 中,关系距离度量模块 g_ϕ 最终产生 $0 \sim 1$ 的标量,表示 x_i 和 x_j 之间的相似性。对于 $k > 1$ 的 k -shot,对每个训练任务中所有样本的嵌入模块输出元素进行求和,再如上所述进行模型训练。

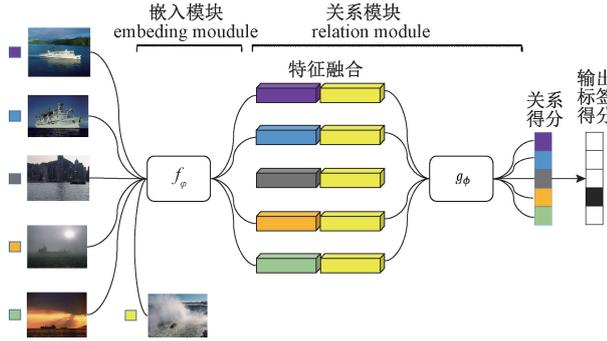


图2 5类别-1标注标签-1查询集样本关系网络结构

Fig. 2 5 way-1 shot-1 query relationnet structure

1.2 跨目标全局注意力机制的模型设计

如图3所示,基于所有目标的类别,本文尝试用全局注意力机制学习目标固有特征,保证目标特征在不同的视觉变化下是不变的。本文提出的跨目标全局注意力机制的总体结构主要由 Conv 和 FC 的组合构成 UAN,参数如表1所示。不同通道卷积层的输出和全连接层的结合使用,使得目标区域关键点特征更加精确,感受野范围更大,更着重于全目标中关注不同类别之间的不变特征,寻求目标特征之间的相似性,同时避免因部分类别样本量过少,特征提取样本信息量少,导致训练过程中产生过拟合现象。因此,本文使用的全局注意力机制通过不同层 Conv Block 卷积神经网络的输出组合,使图像更加关注目标区域特征,增大目标特征区域感受范围,增大目标区域样本信息量,提高新类别识别精度。

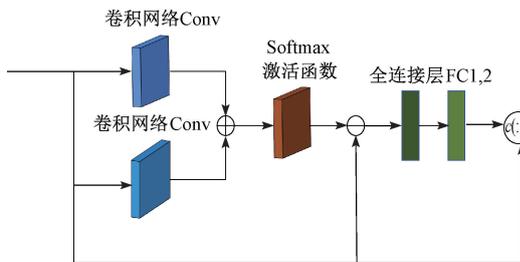


图3 跨目标全局注意力机制(UAN)

Fig. 3 Cross target global attention mechanism(UAN)

表1 全局注意力关系网络模型参数

Table 1 Parameters of the global attention relationship network model

网络块	层类型	卷积核大小	卷积核个数	步长	Padding	激活函数
Conv Block 1	卷积	3	1	1	Same	ReLU
	池化	2	2	2	Same	0
Conv Block 2	卷积	3	1	1	Same	ReLU
	池化	2	2	2	Same	0
Conv Block 3	卷积	3	1	1	Same	ReLU
	池化	2	2	2	Same	0
Conv Block 4	卷积	3	1	1	Same	ReLU
	池化	2	2	2	Same	0
Conv Block(1)	卷积	3	1	1	Same	ReLU
	池化	2	2	2	Same	0
Conv Block(2)	卷积	3	1	1	Same	ReLU
	池化	2	2	2	Same	0
Conv1	卷积	1	1	1	Same	Softmax
Conv2	卷积	1	1	1	Same	Softmax
FC1	全连接	0	23 104	0	0	0
FC2	全连接	0	600	0	0	0
FC3	全连接	0	23 739	0	0	0
FC4	全连接	0	600	0	0	Sigmoid

Conv Block (4) 用于提取图像相应的特征 $f \in R^{w \times h \times c}$, w, h, c 分别表示宽度、高度和通道数,参数如表1所示。然后,将提取的特征 f 一部分输入到全局注意力(UAN)中,将全局注意力(UAN)定义为 $A = \{\alpha_i \in R^c, i = 1, \dots, D\}$ 。接下来,基于 A , 计算表示图像级信息的描述符:

$$I = w_g * f + b_g \quad (1)$$

$$V_i = \sum_{j=1}^{nh} \frac{e^{I_{j,i}}}{\sum_{j=1}^D e^{I_{j,i}}} (f_j - \alpha_i) \quad (2)$$

其中, $w_g \in R^{1 \times 1 \times c \times D}$ 和 $b_g \in R^D$ 是卷积的参数。 $V_i \in R^{D \times c}$ 表示输出描述符。 $f_j - \alpha_i$ 表示残差操作。最后我们将 f 和 V_i 的全连接结果融合作为全局注意力输出部分与 RN 的输出部分做融合。

1.3 跨目标全局注意力与关系网络融合识别

本文采用的主体特征提取 (feature maps) 网络结构由4个 Conv Block 模块构成,该网络属于轻量级,运算时间短,可防止参数量过大导致小样本船舶数据集在训练过程中出现过拟合现象,更便于应用在实际海面船舶目

标识识别中。支持集 (support) 和查询集 (query) 在特征提取过程中加入跨目标全局注意力机制 (UAN) 如图 4 所示,使模型更多的从数量多的样本中学习目标特征、目标类别和新类别中的少量样本信息,同时更多的学习样本在多场景及复杂海况情况下的信息,描述无变化的样本特征,减轻不均衡类别、样本及标签数量少的目标过拟合现象。提高模型新类别目标识别精度。

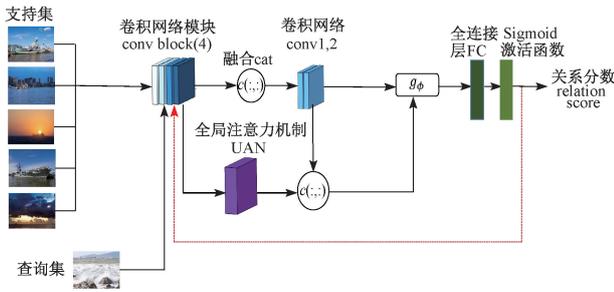


图 4 全局注意力关系度量网络结构

Fig. 4 Universal attention relationnet measurement structure

全局注意力关系度量网络结构中,将小样本船舶数据集随机选择 C 个类别 (其中每个类别有 K 个标记样本) 来形成每个训练任务,以充当样本集合, $S = \{(x_i, y_i)\}$, $m_i = 1, m = k \times C$, C 类样本的其余部分未标记的样本,用作查询集 $Q = \{(x_i, y_i)\}$, $n_{j=1}$ 。每个训练任务传入到卷积神经网络 Conv Block(4) 中,输出提取的特征 f ,从 Conv Block(4) 中提取两支路作为全局注意力机制的输入部分,将 UAN 的输出定义为 P :

$$P = \text{ReLU}(c(f, V_n w_s + b_g)) \quad (3)$$

式中: $V_n \in R^{1 \times D_c}$ 是 V_i 重塑 (reshape) 后的输出,经过全连接层后和 f 的输出组合后激活输出。 $w_s \in R^{D_c \times c}$ 和 $b_g \in R^c$ 是全连接层的参数。经过支持集和查询集馈入样本进行样本特征提取,并输出两者特征融合算子 $c(f_\varphi(x_i), f_\varphi(x_j))$ 的维度为 $64 \times 19 \times 19$,UAN 的输出 P 维度为 $64 \times 19 \times 19$,二者进行融合后输入到特征余弦距离度量 g_ϕ 模块中,计算度量支持集和查询集样本的相似度。训练时通过度量损失的大小进行梯度反向更新,不断进行模型参数优化 (图 4 中虚线部分),寻找最佳参数得出高分模型。其中特征余弦距离度量输出定义为 $r_{i,j}$ 。

$$r_{i,j} = g_\phi(c(P_k, f_\varphi(x_i), f_\varphi(x_j))) \quad (i, j, k = 1, 2, \dots, C) \quad (4)$$

损失函数则采用均方误差函数 (MSE),定义 support set 中的图像为 embedding i , query set 中的图像为 embedding j ,而关系模型 (relation module) 实际上并不是输出的 0,1 的值,而是由 embedding i 和 embedding j 计算介于 0~1 之间的 score,定义为式 (5)。

$$\phi, \varphi \leftarrow \underset{\phi, \varphi}{\text{argmin}} \sum_{i=1}^m \sum_{j=1}^n (r_{i,j} - 1(y_i = y_j))^2 \quad (5)$$

其中, y_i, y_j 代表图片的真实标签, $r_{i,j}$ 为全局注意力关系度量网络组合后式 (4) 的输出,传入全连接层后,依据式 (5) 计算特征相似度,并进行梯度更新迭代,寻找模型最高得分作为船舶目标识别的输出结果。

2 实验结果与分析

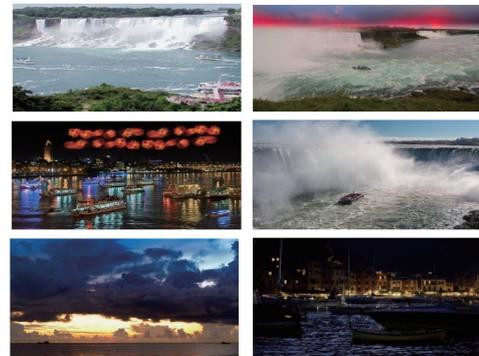
2.1 数据集和实验环境

现有的船舶目标识别使用的数据集方法多为公共单背景数据集 (如 Sea Ships^[17]),或由公共数据和部分自收集数据组成的混合数据集,建立的目标类别数量非常有限。基于真实海面的复杂海况信息下的数据集,这些有限方法识别新类别的准确度通常较低或模型训练过程出现严重过拟合现象。因此,在本文中,自己制作了多场景船舶目标识别数据集,场景信息丰富,覆盖真实海况信息,目标类别数量丰富。研究使用的数据集由 59 个类别组成,共 11 532 个样本图像。训练样本和测试样本的比值约为 4:1。每个样本类别都包含单一背景,真实场景及多场景样本,如图 5 所示。实验环境主要配件及软件版本如表 2 所示。



(a) 单一背景船舶图像

(a) Single background ship image



(b) 多场景复杂海况背景船舶图像

(b) Ship image with multi scene and complex sea state background



(c) 真实海况背景船舶图像
(c) Real sea state background ship image

图5 真实多场景复杂海况船舶数据集

Fig. 5 Real multi-scene and complex sea state ship data set

表2 实验环境及软件版本

Table 2 Experimental environment and software version

系统环境	Ubuntu20. 04
GPU 版本	RTX3090
CUDA 版本	11. 2
Pytorch	1. 7
Optimizer	SGD
学习率	0. 001

2.2 实验结果分析

为证明本文所提出的全局注意力机制的有效性,采取在自己制作的复杂海况、多场景、不平衡小样本数据集上进行船舶目标识别实验,如图5所示,参数样本量分布情况如图6所示(纵轴为模型训练类别名称,横轴为各类别样本数量),并于RN网络单独提出的基于元学习的关系度量网络目标识别算法进行对比,验证了加UAN的RN网络在小样本数据集不平衡类别模型训练,以及复杂多场景海况情况下更有优势。

1) 实验1:基于RN网络的准确率与性能

RN网络未使用传统船舶目标识别迁移学习的预训练方式,而直接采用元学习将数据集划分为训练集44类,验证集9类、测试集6类,目标类别间无交叉。实验设置每个任务集随机抽取5类(Way)样本,从Support Set中每一类随机选取一个样本,一起组成一组训练数据,输入到模型中,进行训练,从Query Set中随机抽取一个无标签样本,用于余弦距离度量模型判断其属于哪一类。设置样本输入为 84×84 ,初始学习率为0.001,训练时损失连续增加五次及以上,缩减为原来的1/10,分类网络的优化器采用SGD,训练周期为200 000 episode,每5 000 episode进行test accuary输出,其中test_episode设置为600 episode。RN网络的Loss值变化趋势如图7所示。可以看出加入全局注意力网络UAN的RN网络模型收敛速度更快,训练过程比RN网络更加稳定。

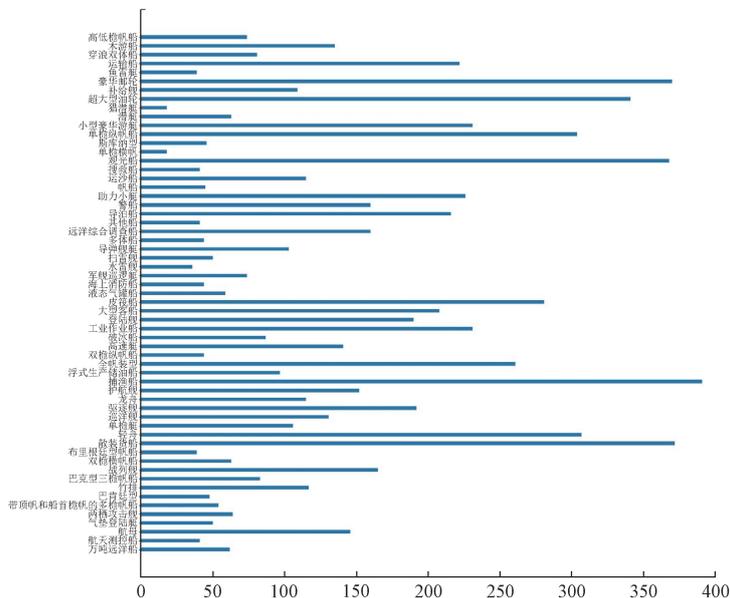


图6 船舶数据集样本分布

Fig. 6 Sample distribution of ship dataset

2) 实验2:基于UAN与RN网络融合的准确率与性能

在UAN与RN融合的模型训练阶段,UAN的加入使

得模型更快的收敛,如图7所示,并且模型在不断学习目标不变特征的信息下,增强网络特征获取能力。关系网络与全局关系度量网络的5类-5标注的准确率和置信度

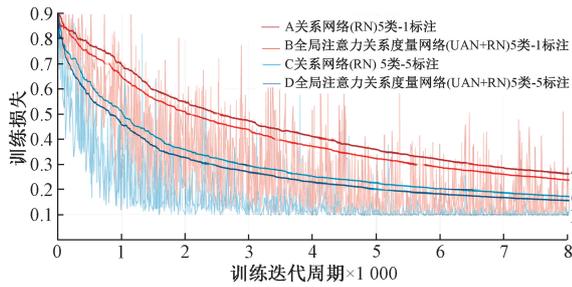
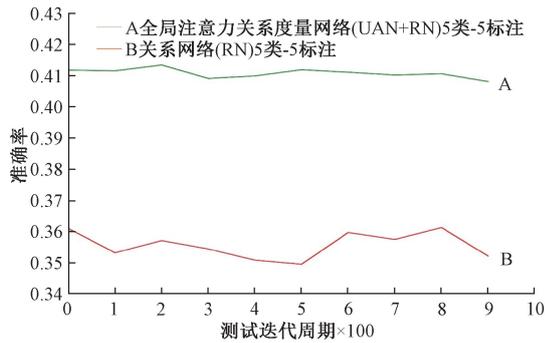


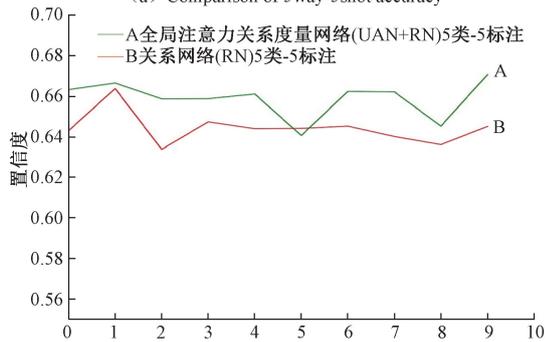
图 7 模型训练损失图 (training loss)

Fig. 7 Model training loss diagram (training loss)

变化趋势分别如图 8(a) 和 (b) 所示。如图 9(a) 和 (b) 所示,分别显示了关系网络与全局关系度量网络的 5 类-1 标注的准确率与置信度变化趋势。可以看出与 RN 网络相比,加入 UAN 的 RN 网络实现了更快的收敛速度,更低的损失和更高的准确率,UAN 的加入也使得准确率及训练损失曲线图更加平滑,有效减小过拟合现象,提高船舶目标新类别识别准确率。



(a) 5类-5标注标签准确率 (accuracy) 对比
(a) Comparison of 5way-5shot accuracy

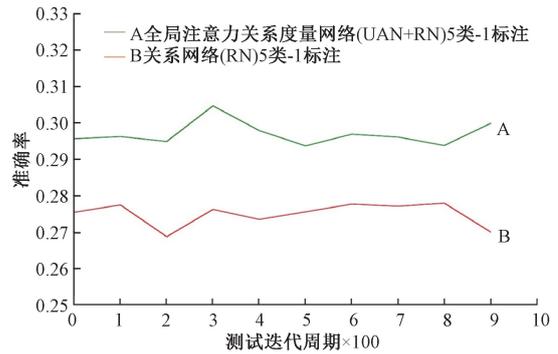


(b) 5类-5标注标签置信度 (confidence) 对比
(b) Comparison of 5way-5shot confidence

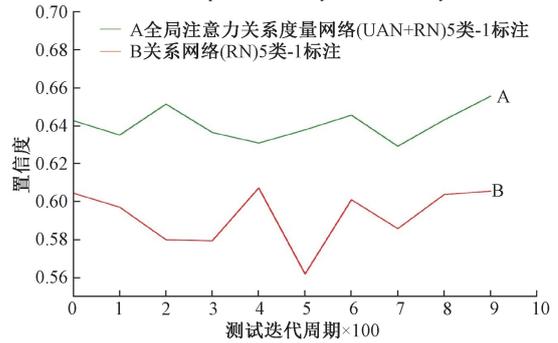
图 8 5 类-5 标注标签准确率 (accuracy) 及置信度 (confidence) 对比

Fig. 8 Comparison of 5way-5shot accuracy and confidence

从不断变化的模型置信度参数和损失值的下降趋势中,得出加入全局注意力的关系网络更多的让 UAN 模块学习到感兴趣的目标区域特征,避免陷入算法局部最优



(a) 5类-1标注标签准确率 (accuracy) 对比
(a) Comparison of 5way-1shot accuracy



(b) 5类-1标注标签置信度 (confidence) 对比
(b) Comparison of 5way-1shot confidence

图 9 5 类-1 标注标签准确率 (accuracy) 及置信度 (confidence) 对比

Fig. 9 Comparison of 5way-1 shot accuracy and confidence

可能。在保证模型训练不发生拟合的同时,最大提高了模型船舶目标新类别识别精度。

此外灵敏度和特异性也是评估性能的测量指标。本研究采用模型的识别准确率指标,还采用精确度、灵敏度和特异性指标进行了比较。

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

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (8)$$

$$Specificity = \frac{TN}{TN + FP} \quad (9)$$

其中, TP (真正样本) 表示实际预测的样本属于类别 C 并被分类器正确识别, FN (假负样本) 是相反的,它是样本的错误识别。 FP (假正样本) 是样本不属于 C 类但被错误地归类为此类。 TN (真负样本) 是样本不属于 C 类,并且它们被正确分类。其准确率 (accuracy)、精确度 (precision)、置信度 (confidence)、灵敏度 (sensitivity)、特异性 (specificity) 对比如表 3 所示。

表 3 关系网络与全局注意力关系网络的对比
Table 3 The comparison between RN network and UAN network

类别个数	全局注意力关系网络		关系网络	
	5-shot	1-shot	5-shot	1-shot
5-way				
准确率	0.421	0.306	0.356	0.274
精确度	0.488	0.286	0.443	0.157
灵敏度	0.452	0.363	0.358	0.254
特异性	1	1	1	1
置信度	0.659	0.641	0.644	0.592

从表 3 中可以看出,特异性代表正确样本误识别情况。RN 网络和加入 UAN 的 RN 网络均不存在正确样本误识别情况,减小了模型的误判能力,提高了模型的识别能力。置信度代表目标样本提取的特征分布比例。加入 UAN 的 RN 网络在置信度分布上比原始 RN 网络提升了 1.5%(5-shot)、4.9%(1-shot),目标样本特征分布更多,有利于提取与目标区域相关更多空间和语义。准确率、精确度和灵敏度总体上优于 RN 网络,有效证明了提出的 UAN 全局注意力可以更多关注目标所在区域样本特征,减少背景和干扰条件等假正样本特征信息,提高多场景下船舶目标识别的精度。

3 结 论

本文针对复杂海况,多场景及真实场景下不均衡类别的小样本船舶目标识别问题,提出了一种跨目标通用全局注意力机制(UAN)与关系度量网络融合的小样本船舶目标识别算法。该方法通过在关系网络(RN)中引入全局注意力机制(UAN),利用 RN 提取到的原始特征,经过全局注意力机制(UAN)平滑不均衡类别间的目标特征,并与 RN 提取的原始特征融合后进行特征距离度量。增强了全局目标特征间的一致性,更关注不变的目标特征区域,提升目标识别精度,增强模型鲁棒性。实验结果表明全局注意力关系网络对不变特征的利用率较高,较 RN 模型的方法取得了更高的识别率,并验证了提出算法的有效性。本文的小样本数据集包含细粒度船舶样本,在复杂背景和海况信息情况下特征区域提取不足,尚需要更佳的模型算法来提升精度。

参考文献

- [1] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.
- [2] 陈宏. 结合多视角-多特征的 SAR 图像目标识别方法[J]. 电子测量与仪器学报, 2019, 33(9):87-92.
CHEN H. SAR image target recognition method combining multi-view and multi-feature [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(9):87-92.
- [3] 李亚娟. 结合全局和局部稀疏表示的 SAR 图像目标识别方法[J]. 电子测量与仪器学报, 2020, 34(2):165-171.
LI Y J. SAR image target recognition method combining global and local sparse representation [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2):165-171.
- [4] 刘峰, 沈同圣, 马新星. 特征融合的卷积神经网络多波段舰船目标识别[J]. 光学学报, 2017, 37(10):248-256.
LIU F, SHEN T SH, MA X X. Multi band ship target recognition based on convolutional neural network with feature fusion [J]. Journal of Optics, 2017, 37(10):248-256.
- [5] HUISMAN M, VAN RIJN JN, PLAAT A. A survey of deep meta-learning [J]. Artificial Intelligence Review, 2021, 54(6):4483-4541.
- [6] JANKOWSKI N, DUCH W, GRĄBCZEWSKI K. Meta-learning in computational intelligence [M]. Springer Science & Business Media, 2011:97-115.
- [7] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]. International Conference on Machine Learning. PMLR, 2017:1126-1135.
- [8] CHEN W Y, WANG Y C F, LIU Y C, et al. A closer look at few-shot classification [C]. Proceedings of the 7th International Conference on Learning Representations, ICLR 2019, May 6, 2019-May 9, 2019, 2019.
- [9] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: Relation network for few-shot learning [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018:1199-1208.
- [10] WU A M, HAN Y H, ZHU L CH, et al. Universal-prototype enhancing for few-shot object detection [J]. ArXiv Preprint, 2021, arXiv:2013.01077.
- [11] HSU K, LEVINE S, FINN C. Unsupervised learning via meta-learning [C]. Proceedings of the 7th International Conference on Learning Representations, ICLR 2019, May 6, 2019-May 9, 2019, 2019.
- [12] KHODADADEH S, BOLONI L, SHAH M. Unsupervised meta-learning for few-shot image classification [C].

- Proceedings of the 33rd Annual Conference on Neural Information Processing Systems, NeurIPS 2019, December 8, 2019-December 14, 2019, 2019.
- [13] LOPEZ-PAZ D, RANZATO M A. Gradient episodic memory for continual learning[J]. Advances in neural information processing systems, 2017, 30: 6467-6476.
- [14] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[C]. Proceedings of the 5th International Conference on Learning Representations, ICLR 2017, April 24, 2017-April 26, 2017, 2017.
- [15] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[C]. Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 1025-1035.
- [16] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 1199-1208.
- [17] SHAO Z, WU W, WANG Z, et al. Seaships: A large-scale precisely annotated dataset for ship detection[J]. IEEE Transactions on Multimedia, 2018, 20(10): 2593-2604.

作者简介



孟浩, 1989 年于哈尔滨船舶工程学院获得学士学位, 1992 年于哈尔滨船舶工程学院获得硕士学位, 2003 年于哈尔滨工程大学获得博士学位, 现为哈尔滨工程大学教授、博士生导师, 主要研究方向为智能感知与视觉技术。

E-mail: menghao@hrbeu.edu.cn

Meng Hao received his B. Sc. degree and M. Sc. degree both from Harbin Shipbuilding Engineering Institute in 1989 and 1992, and received his Ph. D. degree from Harbin Engineering University in 2003. He is currently a professor and a Ph. D. advisor at Harbin Engineering University. His research interests include intelligent sensing and machine vision detection technology.



田洋(通信作者), 2015 年于东北电力大学获得学士学位, 现为哈尔滨工程大学博士研究生, 主要研究方向为船舶智能感知与目标识别。

E-mail: tianyang@hrbeu.edu.cn

Tian Yang (Corresponding author) received her B. Sc. degree from Northeast Dianli University in 2015. She is currently a Ph. D. candidate at Harbin Engineering University. Her main research interests include ship intelligent sensing and target recognition.