

基于非配对图像间转化弱监督学习的 输电线路检测

邱家峰[†], 刘新民, 隆中强, 杨宇轩, 马浩然, 陈玉军

(国网新疆电力有限公司 昌吉供电公司, 新疆 昌吉 831100)

摘 要:为了利用 UAV 航拍图像检测输电线路从而确保电力系统稳定运行,提出了一种基于弱监督学习和非配对图像间转化的输电线路检测方法。利用弱监督学习框架生成输电线路的定位掩码,通过引入新的并行扩展注意力(PDA)模块整合来自不同感受野的信息,从而重新校准通道重要性并提高检测精度。采用基于关联规则学习的算法生成伪线数据集,运用 PDA 中的注意力定位掩码(ALM)和伪线数据之间的非配对图像间转化技术构建精炼网络,从而增强输电线路的线形特性,实现了仅需图像级标签即可直接检测。实验结果表明,就 F1 分数而言,所提出的检测方法比目前最先进的递归噪声样本更新(RNLU)方法优越 2.74%,并在消融实验中验证了精炼网络每个步骤都具有有效性。

关键词:弱监督学习;图像间转化;输电线路;无人机;注意力机制

中图分类号:TP391.41;TM75 **文献标识码:**A

Transmission Line Detection Based on Weakly Supervised Learning of Unpaired Image Transformation

QIU Jiafeng[†], LIU Xinmin, LONG Zhongqiang, YANG Yuxuan, MA Haoran, CHEN Yujun

(Changji Power Supply Company of State Grid Xinjiang Electric Power Co., Ltd., Changji, Xinjiang 831100, China)

Abstract: In order to use UAV aerial images to detect transmission lines to ensure the stable operation of power system, a transmission line detection method based on weak supervised learning and non paired image transformation is proposed. The weak supervised learning framework is used to generate the location mask of the transmission line. By introducing a new parallel dilated attention (PDA) module to integrate information from different receptive fields, the importance of the channel is recalibrated and the detection accuracy is improved. The algorithm based on association rule learning is used to generate pseudo wire data set, and the refining network is constructed by using the attention location mask (ALM) in PDA and the non paired image conversion technology between pseudo wire data, so as to enhance the linear characteristics of transmission lines and realize direct detection only by image level labels. The experimental results show that the proposed detection method is 2.74% better than the current most advanced recursive noise-based learning update (RNLU) method in terms of F1 score, and the ablation experiments verify that each step of the refining network is effective.

Key words: weak supervised learning; image to image conversion; transmission line; UAV; attention mechanism

近年来,无人机(UAV)已广泛应用于许多工业领域。大多数 UAV 都通过机载摄像机进行视

觉识别,并在准确识别周围环境的基础上自动完成飞行路径规划与控制^[1]。对于障碍物检测和避障

的研究,文献[2]使用了基于深度学习的识别算法来检测多个障碍物。另一方面,许多研究致力于基于深度学习方法的避障和路径规划。文献[3]提出了基于深度强化学习的避障系统框架,利用障碍地图规划全局路径。文献[4]提出了基于卷积神经网络(CNN)模型的路径规划方法,可以检测和定位建筑物等障碍物。

在广泛的公共数据集支持下,深度学习技术在各个工业领域逐渐表现出了优越性^[5]。然而,监督学习方法需要借助真实数据,特别是对于大型数据集,将导致高昂的人工成本和时间消耗。文献[6]提出了基于 U-Net 和类激活映射组合的分割算法,仅使用图像级标签即可进行训练,证明了训练具有弱监督的 CNN 模型也可以准确地在航拍图像中分割出耕田。

在众多类型的障碍中,输电线路是 UAV 必须避免的关键障碍。与输电线路碰撞会破坏稳定的电力供应。深度学习方法已成功应用于输电线路的检测和定位^[7]。对于输电线路数据集,由于背景区域占据了航拍图像的大部分,从而导致类不平衡问题。文献[8]通过引入弱监督学习方法来检测输电线路,并采用文献[9]提出的可视化反向传播(VBP)算法来定位输电线路。文献[10]仅使用补丁级标签来降低收集像素级真实数据的成本,从而扩展了输电线路检测研究。文献[11]通过假设输

电线路部分为直线,利用线路方向判别输电线路是否断线。然而,补丁级标签需要借助图像中输电线路的粗略位置信息。

针对 UAV 航拍图像中的输电线路检测问题,本文提出了一种基于弱监督学习和非配对图像间转化的检测方法。与以往需要借助像素级标签的方法不同,本文方法在准备训练数据时仅需要较少的图像级标签即可直接进行检测。通过将新的注意力模块集成到分类网络中,从而获得具有鲁棒性的定位掩码。为了整合来自不同感受野的信息,还引入了并行扩展注意力(PDA)模块。对于精炼网络的训练,通过非配对图像间转化生成伪线数据精炼定位掩码,并结合循环一致性损失设计了生成器。精炼网络增强了输电线路的线形特性,从而显著提升了定位结果在定性和定量方面的性能。

1 研究框架

利用弱监督学习框架生成输电线路的定位掩码,同时,引入新的注意力机制 PDA 来提高定位掩码的质量,即注意力定位掩码(ALM)。此外,运用 ALM 和伪线数据之间的非配对图像间转化技术设计了精炼网络。本文提出的输电线路检测研究框架如图 1 所示。




图 1 本文方法研究框架

在图 1 中,左侧部分为提取电力线(PL)特征和 VBP 算法获取定位掩码的基础网络,右侧部分

为精炼网络和用于精炼网络对抗学习的精炼子网。其中,左上角为有输电线路和无输电线路图像分类

的主干网络;左下角为从分层特征图生成 ALM 的过程;右上角为精炼网络对抗训练的鉴别器;右下角为生成精细图像的精炼网络生成器。

2 分类网络和 VBP 算法

利用 VBP 算法^[12]生成定位掩码。为了得到用于定位输电线路的掩码,对卷积块的最后一个特征图 $F_i \in R^{H_i \times W_i \times C_i}$ 采用 VBP 算法。第 i 个特征图 F_i 由 C_i 个特征图 $f_i^1, \dots, f_i^{C_i}$ 组成。VBP 算法的第一个过程是通过将深度方向上的特征图 $f_i^k \in R^{H_i \times W_i}$ 累加计算得到单个特征图:

$$\bar{f}_i = \sum_{k=1}^{C_i} f_i^k \quad (1)$$

其中, i 和 C_i 分别为卷积块和信道的数量。通过双线性插值对累积的特征图进行上采样从而生成 h_i , 并将其与之前的特征图 $\bar{f}_{i-1}$ 相乘得到:

$$\tilde{h}_{i-1} = \bar{f}_{i-1} \otimes h_i \quad (2)$$

其中, $\otimes$ 为逐元素乘法运算。

提出了一种弱监督学习的注意力机制,从而增强输电线路在定位图中的响应。在图 1 中, $\tilde{F}_i \in R^{\frac{H_i}{2} \times \frac{W_i}{2} \times C_i}$ 为 VGG16 中第 i 个卷积块的输出,从而对 F_i 进行 ReLU 和最大池化后得到用于下一个卷积块的输入。

3 并行扩展注意(PDA)模块

受挤压和激励网络(SE-Net)^[13]与高效渠道关注网络(ECA-Net)^[14]的启发,引入新的注意力机制 PDA 模块。提出的 PDA 模块结构如图 2 所示。




图 2 PDA 模块结构

在图 2 中,将 PDA 模块的膨胀比分别设置为 1、2 和 4 的轻量级一维卷积,并将填充设置为膨胀比来获取与输入长度相同的输出向量。在 PDA 中,将全局平均池化(GAP)应用于特征图得到大小为 $1 \times 1 \times C$ 的向量,其中, C 为通道数。使用 Sigmoid 函数得到 $0 \sim 1$ 之间的注意力向量:

$$\mathbf{a} = [a_1, \dots, a_{C_5}], 0 \leq a_k \leq 1 \quad (3)$$

从最后一个卷积块计算注意力向量 $\mathbf{a}$, $\mathbf{a}$ 的长度等于通道数。 $\mathbf{a}$ 的每个组成部分表示相应通道的重要性,因此,PDA 引导网络将重点放在对输电线路进行分类和定位的重要特征上。基于 PDA 的局部掩码称为 ALM。分类网络中的 PDA 模块如图 3 所示。




图 3 分类网络中的 PDA 模块

PDA 模块位于最后一个卷积特征图和 ReLU 运算之间。最后一个卷积特征图 F_5 由 $f_5^1, \dots, f_5^{C_5}$ 组成,加权特征图 $G \in R^{\frac{H_5}{2} \times \frac{W_5}{2} \times C_5}$ 的第 k 个通道可以计算为:

$$g^k = a_k \otimes f_5^k \quad (4)$$

利用注意力加权特征图进行输电线路定位。与 VBP 算法中的求和运算不同,本文将从 PDA 模块中计算出的注意力向量的分量进行加权求和。与公式(1)相同,加权特征图 G 在深度方向上累加计算得到累加特征图:

$$\bar{g} = \sum_{k=1}^{C_5} g^k \quad (5)$$

为了使 $\bar{g}$ 与其他特征图合并,将 $\bar{g}$ 上采样到与先前特征图 $\bar{f}_4$ 相同的大小,该过程可以表示为:

$$h_5 = \text{Upsampling}(\bar{g}) \quad (6)$$

其中, Upsampling 为双线性插值。通过公式(2),在 h_5 和 $\bar{f}_4$ 之间进行逐元素乘法运算,重复该过程,直至得到 h_1 ,即 ALM。

4 基于图像间转化的精炼网络

构建了传递输电线路视觉特征的精炼网络。精炼网络采用图像间转化架构的生成器。为了传递输电线路的线形属性,采用基于关联规则学习^[15]的算法生成伪线数据集。伪线数据集包括

250 幅二进制伪线图像,图像大小为 512×512 ,与 ALM 的大小相同。生成伪线数据集的过程如图 4 所示。




图 4 生成伪线数据集的过程

准备一幅填充 0 的图像,并使用随机选择的像素坐标 a 和 b 生成伪线,其中, a 和 b 为 $0 \sim 512$ 之间的整数。由于多条线相互太近,所以本文生成了伪线连接图像的相反面。同时,由于 PL 数据集包含多条输电线路,因此本文还生成了输电线路数量可变的伪线数据集。在图 4 中, i 表示任意线间隔,以 i 的距离生成多条线。通过利用伪线数据集的属性改进了 ALM,从而提高定位精度。

为了构建精炼网络,采用了循环生成对抗网络(CycleGAN)^[16] 结构,分别将 ALM 定义为源域 S ,伪线数据集定义为目标域 T 。为了训练精炼网络,构造了两个生成器和两个鉴别器用于非配对图像间转化框架的对抗训练。从源域 S 映射到目标域 T 的第一个生成器用 $G: S \rightarrow T$ 表示,如图 1 右下角所示。生成器 G 允许 ALM 包含伪线图像的属性,并将其用作精炼网络。通过训练第一鉴别器 D_T 来区分 $G(s)$ 和目标域 T 中的伪线数据集,其中, $G(s)$ 是从源域 S 生成的图像。随着对抗训练的进行,生成器 G 将创建真实的线路图像,即精炼 ALM。鉴别器 D_T 在图 1 的右上角,训练 G 和 D_T 的对抗损失定义为:

$$L_{\text{adv}}(G, D_T, S, T) = E_{t \sim p_{\text{date}}(t)} [\log(D_T(t))] + E_{s \sim p_{\text{date}}(s)} [\log(1 - D_T(G(s)))] \quad (7)$$

其中, E 为编码器, $p_{\text{date}}(t)$ 和 $p_{\text{date}}(s)$ 分别为目标域 T 和源域 S 的分布。

同样,第二个生成器 $F: T \rightarrow S$ 将目标域 T 数据映射到源域 S ,第二鉴别器 D_S 对源域 S 中的 ALM 和重构 ALM 进行区分。 F 和 D_S 训练的另一个对抗损失定义为:

$$L_{\text{adv}}(F, D_S, T, S) = E_{s \sim p_{\text{date}}(s)} [\log(D_S(s))] + E_{t \sim p_{\text{date}}(t)} [\log(1 - D_S(G(t)))] \quad (8)$$

由于仅使用对抗损失可能导致模式崩溃,因此采用循环一致性损失^[17] 在受限空间中训练生成器。基于循环一致性损失定义为:

$$L_{\text{cycle}}(G, F) = E_{s \sim p_{\text{date}}(s)} \|F(G(s)) - s\| +$$

$$E_{t \sim p_{\text{date}}(t)} \|G(F(t)) - t\| \quad (9)$$

将训练精炼网络的总损失函数表示为对抗损失和循环一致性损失的组合为:

$$L(G, F, D_S, D_T) = L_{\text{adv}}(G, D_T, S, T) + L_{\text{adv}}(F, D_S, T, S) + \lambda L_{\text{cycle}}(G, F) \quad (10)$$

其中, λ 为控制循环一致性损失效应的超参数,在实验中使用 $\lambda = 10$ 。

生成精炼 ALM 的过程,如图 5 所示。生成器 G 将 ALM 映射到目标域 T ,因此,基于目标域 T 数据的线性特性使得输电线路的响应得到增强。




图 5 生成精炼 ALM 的过程

5 实验分析

在 Intel Core i9-10900K CPU、64 GB DDR4 RAM 和 NVIDIA RTX 3090 等硬件环境下进行实验。所提出的算法基于 PyTorch 和 OpenCV 实现。为了训练分类网络,使用初始学习率为 0.0001,权重衰减为 0.05 的 Adam 优化器。

5.1 数据集描述

使用了由 400 幅红外(IR)和 400 幅可见光(VL)图像组成的公共电力线数据集。该数据集收集了昌吉市 21 个不同地区的 UAV 航拍数据。本文使用了 400 幅大小为 512×512 的 VL 图像,其中 200 幅 VL 图像包含输电线路,其他的 VL 图像不包含输电线路。示例图像及其对应的真实值数据如图 6 所示。

在图 6 中,第一列和第三列给出了有输电线路和无输电线路的示例图像,真实值对应第二列和最后一列中的每个图像。对于基础分类网络的训练,本文将数据集划分为 300、50 和 50 幅图像,分别用于训练集、验证集和测试集。




图 6 示例图像及其对应的真实值数据

5.2 评价指标

根据文献[11]提出的标准对本文方法进行评
估。根据真阳性(TP)、假阳性(FP)和假阴性(FN)
计算召回率、精确度和 F1 分数。其中,召回率表
示正确预测为正的占全部实际为正的比
例;精确度表示正确预测为正的占全部预测为正的比
例;F1 分数为召回率和精确度的调和平均数,在实验分析
中用于平衡分类模型的召回率和精确度。TP 定义
为正确检测到超过 50%线像素的情况数量。为了
定义输电线路附近出现的错误响应,FP 通过基
于公差范围定义。通过将输电线路两侧的公差范
围设置为 10 像素,FP 包括背景区域中出现的错误
响应和输电线路上的粗略预测。如果预测线由少
于 10 个像素组成,则将其视为噪声。

5.3 定量分析

本文方法与语义分割全卷积网络(SS-FCN)^[18]、注意力融合网络(ANet)^[19]、CNN^[4]、递归噪声样本更新(RNLU)^[20]等方法进行定量比
较,如表 1 所示。其中,最佳结果用粗体突出显示,
次佳结果用下画线突出显示。

表 1 定量比较					
方法	学习类型	标签级别	召回率/%	精确度/%	F1 分数/%
SS-FCN ^[18]	监督	像素	98.17	93.04	95.54
ANet ^[19]	监督	像素	97.25	95.50	96.36
CNN ^[4]	弱监督	补丁	86.24	100	92.61
RNLU ^[20]	弱监督	补丁	98.17	90.68	<u>94.27</u>
本文方法	弱监督	图像	<u>97.90</u>	<u>96.15</u>	97.01

为了表示不同方法的差异,根据学习类型和标
签级别对结果进行分类。依据子类细粒度图像分
类标签级别分为像素级、补丁级和图像级。其中,
像素级能够非常高精度地获取和分析图像的细节
信息,进而进行像素级别的计算和处理;补丁级是

在图像中划分出若干个补丁块,而后对每个补丁块
进行处理和操作;图像级可以利用图像整体信息的
局部性质、边缘检测等特征进行全局分析。弱监督
方式的学习类型可以分为补丁级和图像级标签。
在其他方法中,通过将原始图像划分为 128×128
个子图像,为这些补丁图像指定类标签,并使用补
丁级标签。与像素级标签相比,补丁级标签的计算
量更小,但补丁级标签在需要原始图像中输电线路
的位置信息方面存在局限性。因此,本文利用整个
图像的大小来训练分类网络。在输电线路图像中,
线路由少量像素组成,其余大部分区域由背景组
成。因此,图像尺寸越大,对输电线路的定位和检
测就越困难。然而,通过利用整个图像,本文在数
量上取得了显著的改进。

由表 1 可见,对于弱监督学习类型,与 RNLU
方法相比,本文方法在精确度和 F1 分数方面分别
提高了 5.47%和 2.74%,而召回率略降低了
0.27%。这是由于本文方法从开始到结束都使用
了整个图像进行检测,而 RNLU 方法在检测过程
中先将图像分割成补丁级再合并在一起,在划分补
丁图像的过程中,需要输电线路的近似位置信息来
训练分类网络。然而,本文方法不需要借助任何位
置信息。此外,本文方法还可以通过精炼网络对从
特征图中得到的定位掩码进行改进。CNN 方法在
精确度和 F1 分数方面表现较好,但在精确度和召
回率之间存在权衡,相比之下,本文方法在召回率
和精确度方面综合表现更优。

对于监督学习类型,采用 SS-FCM 和 ANet 的
分割算法在召回率和精确度方面性能更优,但在生
成像素级标签过程中需要花费大量时间。为了降
低真实值数据的准备成本,本文方法采用弱监督学
习类型,只使用了图像级标签,即可在精确度和 F1
分数方面显示出较高的准确性。

5.4 消融实验

对所提出的方法进行消融研究,以此验证方法
中每个步骤的有效性。验证 PDA 模块和精炼网
络有效性的消融研究结果,如表 2 所示。

表 2 验证 PDA 模块和精炼网络有效性的消融研究					
定位掩码	PDA	精炼	召回率/%	精确度/%	F1 分数/%
✓	—	—	90.37	91.90	91.13
✓	✓	—	82.03	92.67	92.35
✓	—	✓	93.96	94.86	94.41
✓	✓	✓	97.90	96.15	97.01

采用了文献[12]的 VBP 算法,该算法可以有效表示卷积网络特征图中的线索,即基准模型,并在表 2 中表示为定位掩码。从 PDA 中得到的注意力向量包含特征图的每个通道分数,分数范围从 0 到 1。计算出的分数乘通道特征图,从而给出每个通道的重要性,并在对输入图像进行二分类时,通过关注学习到的特征进行定位。通过将 PDA 添加到基准,得到 92.35% 的 F1 分数,与无 PDA 模块的定位掩码相比,性能提高了 1.22%。通过将精炼添加到基准,本文方法召回率、精确度和 F1 分数均有显著提升,对于召回率和精确度方面,性能分别提高了 3.59% 和 2.96%。这些结果表明,采用 CycleGAN 作为改进定位掩码的方法,可以通过将全连接的理想线路的特性从一个点转移到另一个点。同时采用 PDA 和精炼这两个步骤的结果性能最佳,召回率和精确度分别为 97.90% 和 96.15%。与基准模型相比,在召回率和精确度方面分别提高了 7.53% 和 4.25%,最终 F1 分数提高了 5.88%。因此。本文方法的每个步骤都有助于成功检测输电线路。

5.5 与其他注意力模块的比较

使用的 PDA 注意力模块与无参通用 (SimAM)^[21]、SE^[13] 和 ECA^[14] 注意力模块进行比较结果,如表 3 所示。

表 3 注意力模块比较

方法	召回率/%	精确度/%	F1 分数/%
SimAM ^[21]	89.88	88.97	89.42
SE ^[13]	89.89	89.52	89.71
ECA ^[14]	90.97	92.08	91.52
本文方法	92.03	92.67	92.35

在上述注意力模块的基础上,利用 VGG16 相同的基准网络获得定位掩码。将本文提出的使用 PDA 的定位精度与其他方法的定位精度进行比较。SE 在所有评价指标中的数值均低于 90%,本文使用的 PDA 注意力模块的精确度比 SE 高 3.15%。此外,ECA 表现出比 SE 更好的性能,但仍低于本文使用的 PDA 的精确度。这是由于 ECA 仅使用一个核进行一维卷积,导致接收域较小,限制了表示输电线路的特征。同时,生成三维权重的 SimAM 不适合本文实验,实验表明,并非所有注意力模块都能有效定位输电线路。与其他方法相比,PDA 模块在所有评价指标中均表现出了更佳的性能。这是由于 PDA 利用三种不同的一维卷

积来捕获丰富的特征表示并有效拓展了接收域。

5.6 定性分析

本文方法检测输电线路的结果如图 7 所示。其中,输入图像和相应的真实值分别如图 7(a)和图 7(b)所示。ALM 是利用从 PDA 获得的注意力向量进行定位掩码,用于更多地关注重要通道。如图 7(c)所示,PDA 可以有效地定位输入图像中的线路,即使在应用精炼网络之前,预测的线路结构和数量也与真实值相似。然而,ALM 中的大多数输电线路表现模糊,部分预测包含断开或缺失部分。为了解决这些限制,将精炼网络应用于 ALM,结果如图 7(d)所示。精炼网络根据目标域数据的特征生成精炼 ALM,对污迹或模糊的线路进行补充,使得线路图像变得更加锐化。精炼网络还可以连接虚线来生成图像的相交线路,即使与真实值数据进行比较,也能提供质量上的可信结果。在图 7(e)中,原始图像与精炼 ALM 重叠。




图 7 本文方法检测输电线路的结果

6 结 论

提出了一种基于弱监督学习和非配对图像间转化的输电线路检测方法。仅使用图像级标签就可以在最少的人工参与下进行训练。该方法包括

两个步骤:基于 PDA 的输电线路定位和通过图像间转化进行精炼。PDA 模块根据来自不同感受野的信息计算得分向量。注意力向量提供目标特征的通道重要性并用于生成 ALM。此外,本文构建了传递输电线路线性形特征的精炼网络,从而改善 ALM 中的弱响应。证明了 PDA 模块在输电线路定位方面优于其他注意力机制。此外,精炼网络在定量和定性方面都显著提高了传输线检测的准确性。在未来的研究中,将致力于设计出更加有效的注意力机制来提高输电线路检测效率。

参考文献

[1] 王继红,吴伯彪,张亚超,等. 视觉和惯导信息融合小型无人机位姿估计研究[J]. 中国测试,2021,47(11): 134-140+152.

[2] 江沛原. 基于深度语义分割的无人机遥感影像水体提取研究[J]. 现代计算机,2022,28(15):50-56.

[3] AHMED B, NEERAJ K, ISHAN B, et al. Deep reinforcement learning based trajectory optimization for magnetometer-mounted UAV to landmine detection[J]. Computer Communications, 2022, 195(2):441-450.

[4] 皮骏,张志力,李想,等. 无人机目标分类的深度卷积网络设计与优化[J]. 计算机系统应用,2021,30(5): 290-297.

[5] 段中兴,王剑,丁青辉,等. 基于深度学习的盲道障碍物检测算法研究[J]. 计算机测量与控制,2021,29(12): 27-32.

[6] 张祖宇,滕永核,秦元丽,等. 基于 U-Net 模型的无人机影像数据地表覆被信息自动提取研究[J]. 广西林业科学,2022, 51(4):516-519.

[7] 戴永东,蒋中军,王茂飞,等. 基于深度学习的输电线路均压环倾斜识别[J]. 自动化仪表,2022,43(9): 106-110.

[8] 陈玉权,王红星,沈杰,等. 基于 ML-S2OCELM 的输电线异物检测方法研究[J]. 南京邮电大学学报(自然科学版), 2020,40(3):89-96.

[9] 王孝余,李丹丹,张立颖. 一种基于监督学习的输电线监测中杆塔的检测方法[J]. 东北电力技术, 2017,38(11):12-14+

19.

[10] 吴鹏,姜海波,王永强,等. 基于图像切片的移动端输电线路鸟类检测算法研究[J]. 计算机与数字工程, 2021,49(4): 846-851.

[11] 王周. 基于航线自主规划的变电站无人机巡检[J]. 自动化仪表,2022,43(6):43-46+53.

[12] CHOI H, KOO G, KIM B, et al. Weakly supervised power line detection algorithm using a recursive noisy label update with refined broken line segments[J]. 2021,165(1): 113-124.

[13] ZHANG X, LI J, HUA Z. MFFE: multi-scale feature fusion enhanced net for image dehazing[J]. Signal Processing: Image Communication, 2022,105(1): 116-129.

[14] LI L, PAN Y, GAO S, et al. An innovative model to design extreme emission control areas (ECAs) by considering ship's evasion strategy[J]. Ocean & Coastal Management, 2022, 227(4):106-118.

[15] 王青松,姜富山,李菲. 大数据环境下基于关联规则的多标签学习算法[J]. 计算机科学,2020,47(5): 90-95.

[16] 徐珑婷,田婉鑫,魏邳林. 基于改进循环生成对抗神经网络的语音增强[J]. 东华大学学报(自然科学版), 2022,48(5): 70-76.

[17] 张志远,杨帆. 结合多注意力机制的自监督目标跟踪[J]. 计算机工程与设计,2021,42(12):3502-3509.

[18] NOUSSAIBA J, ZIED L. Multimodal fusion methods with deep neural networks and meta-information for aggression detection in surveillance[J]. 2022,211(2): 118-123.

[19] JIANG H, GUO Y. Multi-class multimodal semantic segmentation with an improved 3D fully convolutional networks [J], Neurocomputing, 2020,391(28):220-226.

[20] MICHAEL W, THOMAS S, ZHU X, et al. Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019,150(4): 59-69.

[21] 张昌凡,胡新亮,何静,等. 基于 SimAM 和 SpinalNet 的列车轮对踏面缺陷分类模型[J]. 中国安全科学学报, 2022,32(6):38-43.