

生成式知识迁移的SAR舰船检测

娄欣, 王晗, 卢昊, 张文驰

1. 北京林业大学 信息学院, 北京 100083;
2. 国家林业和草原局林业智能信息处理工程技术研究中心, 北京 100083

摘要: 为解决基于深度卷积神经网络进行SAR舰船检测网络训练过程中数据获取、数据标注等问题, 本文提出一种生成式知识迁移的SAR舰船检测框架, 该框架由生成式知识迁移网络和舰船检测网络两部分组成。通过知识迁移网络生成与有标注的光学遥感图像空间分布一致且包含SAR图像特征的带标注模拟图像; 使用所生成的带标注模拟图像, 进一步优化舰船检测网络, 以提高基于深度卷积神经网络的舰船检测的泛化性能。SAR-Ship-Detection-Datasets (SSDD) 和 AIR-SARShip-1.0 两个公开数据集上的实验结果表明, 该框架有效提高了在仅包含少量标注SAR图像样本情况下的舰船目标检测效果, 可显著降低舰船在复杂背景图像中漏检和误检的概率。

关键词: SAR, 目标检测, 深度学习, 图像生成, 迁移学习

中图分类号: P2

引用格式: 娄欣, 王晗, 卢昊, 张文驰. 2024. 生成式知识迁移的SAR舰船检测. 遥感学报, 28(2): 470-480

Lou X, Wang H, Lu H and Zhang W C. 2024. SAR ship detection through generative knowledge transfer. National Remote Sensing Bulletin, 28(2):470-480[DOI:10.11834/jrs.20211354]

1 引言

近年来, 在海洋资源管理、环境保护、水路运输管理、船只救援、战场主动防御等方面的重大需求的引导下, 对港口及海上区域的舰船目标检测成为一项重要的应用任务 (Xie 等, 2016)。由于合成孔径雷达SAR (Synthetic Aperture Radar) 可以全天候、全天时提供高分辨图像, 成为海上目标检测的一种主要途径。SAR图像由于其成像机理和光学图像差别较大, 采用人工目视判读的方法对判读人员的经验水平要求较高, 难以满足海量SAR图像实时解译的需求, 因此研究SAR图像的自动目标检测方法在战场侦察监视、目标识别、精确制导等领域具有重大意义。

传统SAR图像舰船自动检测方法中使用的特征根据具体目标手工设计提取, 如散射特性 (Wang 和 Liu, 2015), 极化特征 (Beltramonte 等, 2020; Zhang 等, 2019; Ma 等, 2018)、几何特征 (Wang

等, 2014)、梯度方向直方图 (Xu 和 Liu, 2016), 尺度不变特征 (Demars 等, 2015) 等。然而, 手工设计特征泛化能力较差, 无法适应复杂场景下多目标舰船检测任务。近年来, 基于深度卷积神经网络CNN (Convolutional Neural Networks) 的方法在复杂背景的光学图像目标检测中取得了较大的进展 (Liu 等, 2016; Ren 等, 2017; Redmon 和 Farhadi, 2018; Bochkovskiy 等, 2020)。基于数据驱动的深度卷积神经网络在进行特征提取时, 通过引入卷积层, 有效降低了神经网络的复杂性, 降低了数据前期的预处理要求, 因此在SAR图像舰船目标检测上的效果明显优于传统的方法 (Gui 等, 2019; Zhang 和 Zhang, 2019; Li 等, 2021)。

虽然基于深度卷积神经网络的目标检测网络在光学图像中取得了很好的效果 (Liu 等, 2016; Girshick, 2015; Ren 等, 2017; Redmon 和 Farhadi, 2018; Bochkovskiy 等, 2020), 但由于SAR图像中目标的特征分布与光学图像中的区别显著, 在光

收稿日期: 2021-05-27; 预印本: 2021-08-25

基金项目: 中央高校优秀青年团队项目(编号:QNTD202308); 国防科技重点实验室基金项目(编号: 614201004012102)

第一作者简介: 娄欣, 研究方向为图像理解。E-mail: louxinll@bjfu.edu.cn

通信作者简介: 王晗, 研究方向为图像理解, 计算机视觉, 人工智能理论和应用。E-mail: wanghan@bjfu.edu.cn

学图像中习得的目标检测网络并不能很好地直接用于SAR图像目标检测任务。为了在SAR目标检测任务中取得较好的泛化效果，仍然需要大量标注数据（孙显 等，2019）作为深度卷积神经网络的训练集。建立一个足够规模的SAR图像数据集不仅需要耗费巨大的经济成本，也对标注人员的专业水平提出了较高的要求。另一方面，获取带有标注的光学遥感图像所耗费的经济成本和人力需求相对较低，更易于获取。

迁移学习（Pan和Yang，2010）通过从一些已有标注的数据域习得知识或者模式信息，应用于不同但相关的数据域或任务中，从而提升目标域中任务的学习效果。由此，考虑生成与包含标注的光学遥感图像空间分布一致的模拟图像从而将光学图像中的空间标注信息迁移至模拟图像；同时对模拟图像的生成过程进行约束使其在特征上更接近于SAR图像，从而使在模拟图像上习得的检测模型能够更好地适用于SAR图像中目标检测。为进行知识迁移，本文首次将循环一致生成对抗损失用于生成训练数据，以解决没有成对光学图像与遥感图像情况下进行知识迁移的困难。同时提出恒等损失以及特征边界决策损失，生成与带标注的光学遥感图像空间分布一致且与SAR图像相似的模拟图像。利用生成的模拟图像，进一步优化舰船检测网络，以提高基于深度神经网络的目标检测网络的泛化性能。

综上所述，本文提出一种基于生成式知识迁

移的SAR舰船检测框架，该框架包含两个模块：知识迁移网络和舰船检测网络。在知识迁移网络中，提出使用循环一致生成对抗损失、恒等损失以及特征边界决策损失，通过学习光学遥感图像域与SAR图像域间的特征映射，生成包含标注信息的模拟图像，解决了SAR图像数据量不足的问题；在舰船检测网络中，通过融合具有空间标注信息的模拟图像和SAR图像对已有基于深度卷积神经网络的目标检测网络进行微调，得到适用于SAR图像域的目标检测网络。在SAR-Ship-Detection-Datasets (SSDD) 和 AIR-SARShip-1.0 两个公开数据集上的实验结果表明，该框架有效提高了在小样本量情况下的舰船目标检测效果，可显著降低舰船在复杂背景图像中漏检和误检的概率。

2 知识迁移网络

针对大量包含标注信息的SAR图像数据集获取成本较高，不足量的数据难以对目标检测网络进行充分有效的训练，提出一种知识迁移网络（如图1左侧所示），通过挖掘光学遥感图像特征空间与SAR图像特征空间之间的映射关系，生成的模拟图像能够保存已有带标注的光学遥感图像空间分布信息又与SAR图像特征分布相似。对知识迁移网络的训练采用对抗训练的方式进行，通过使用循环一致生成对抗损失，恒等损失，特征边界决策损失对训练过程中的网络参数优化进行约束。下面将逐一对每个损失函数及其作用进行详细介绍。

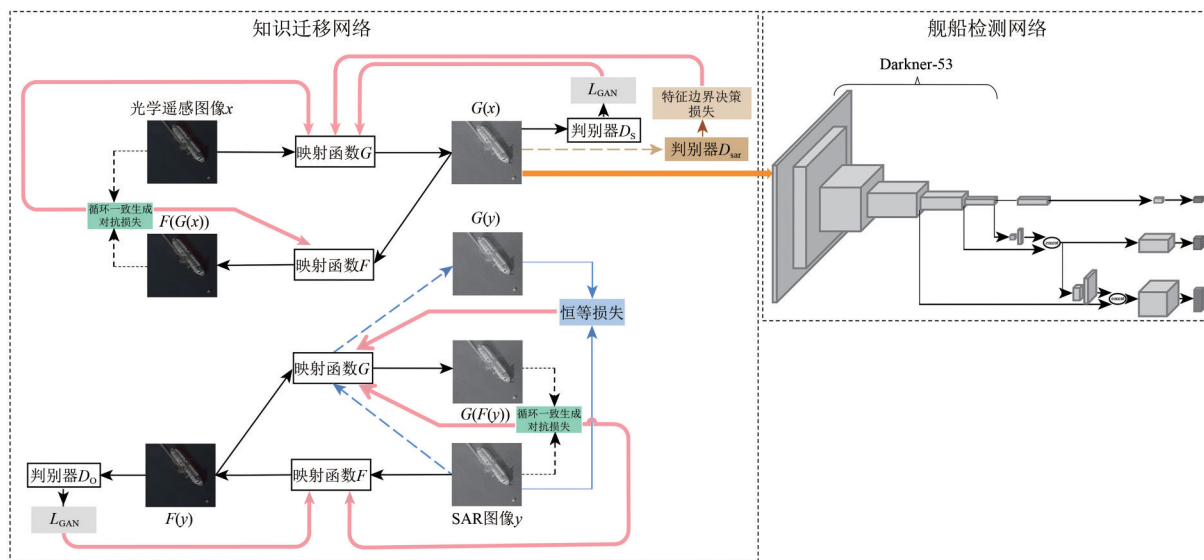


图1 SAR图像目标检测总体框架

Fig. 1 SAR image object detection framework

2.1 循环一致生成对抗损失

不同于传统的数据转换方式需要成对数据进行学习 (Isola等, 2017; Choi等, 2020), 本文方法不依赖于成对的光学遥感图像和SAR图像。为得到与光学遥感图像空间分布一致且与SAR图像特征分布相似的模拟图像, 首先在知识迁移网络中使用循环一致生成对抗损失 (Zhu等, 2017) 来进行生成。

给定光学遥感图像域 \mathcal{O} , 图像 $x \in \mathcal{O}$ 以及 SAR 图像域 \mathcal{S} , 图像 $y \in \mathcal{S}$ 。知识迁移网络可以同时习得光学遥感图像域到 SAR 图像域的映射函数 $G: \mathcal{O} \rightarrow \mathcal{S}$, 用以生成与光学遥感图像 x 对应的模拟图像 $G(x)$, 以及 SAR 图像域到光学遥感图像域的映射函数 $F: \mathcal{S} \rightarrow \mathcal{O}$, 生成与 SAR 图像 y 对应的图像 $F(y)$ 。另外, 使用判别器 D_S 区分 SAR 图像 y 和映射函数 G 所生成的模拟图像 $G(x)$, 以及判别器 D_O 区分光学遥感图像 x 和映射函数 F 所生成的图像 $F(y)$ 。对于映射函数 G 和 F 以及判别器 D_S 和 D_O , 对抗损失函数为

$$L_{\text{GAN}}(G, D_S, \mathcal{O}, \mathcal{S}) = E_{x \sim p_{\text{opt}}(x)} (\log(1 - D_S(G(x)))) + E_{y \sim p_{\text{sar}}(y)} (\log D_S(y)) \quad (1)$$

$$L_{\text{GAN}}(F, D_O, \mathcal{S}, \mathcal{O}) = E_{y \sim p_{\text{sar}}(y)} (\log(1 - D_O(F(y)))) + E_{x \sim p_{\text{opt}}(x)} (\log D_O(x)) \quad (2)$$


式中, $E(*)$ 表示分布函数的期望值, $x \sim p_{\text{opt}}(x)$ 与 $y \sim p_{\text{sar}}(y)$ 分别表示光学遥感图像域与 SAR 图像域的数据分布。映射函数 G 的目标为生成的模拟图像 $G(x)$ 与图像 x 空间分布信息一致且与 SAR 图像特征分布尽可能相似, 而判别器 D_S 则为最大可能区分 $G(x)$ 和 SAR 图像 y 。因此, 希望损失函数能在最小化映射函数 G 的同时最大化判别器 D_S : $\min_G \max_{D_S} L_{\text{GAN}}(G, D_S, \mathcal{O}, \mathcal{S})$ 。相似的, 对于映射函数 F 和判别器 D_O 的优化, 可以表示为: $\min_F \max_{D_O} L_{\text{GAN}}(F, D_O, \mathcal{S}, \mathcal{O})$ 。

为了加强映射函数的生成能力, 认为映射函数的学习过程应该是循环一致的, 如图 2(a) 所示。在图像生成循环过程中, 对于 \mathcal{O} 域中的每个图像 x , G 和 F 满足前向循环一致可以将 x 还原, 即 $x \rightarrow G(x) \rightarrow F(G(x)) \approx x$, 类似地, 对于 \mathcal{S} 域中的图像 y , 后向循环一致也可以将 y 还原, 即 $y \rightarrow F(y) \rightarrow G(F(y)) \approx y$ 。由此, 可以得到循环一致

生成对抗损失函数:

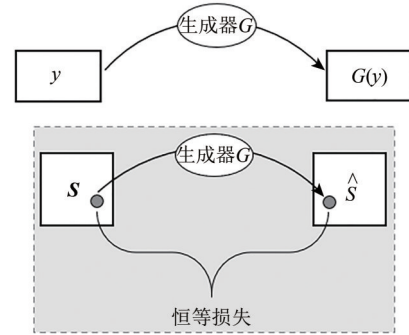
$$L_{\text{cyc}}(G, F) = E_{x \sim p_{\text{opt}}(x)} [\|F(G(x)) - x\|_1] + E_{y \sim p_{\text{sar}}(y)} [\|G(F(y)) - y\|_1] \quad (3)$$

式中, $\|\cdot\|_1$ 为 L1 范数。



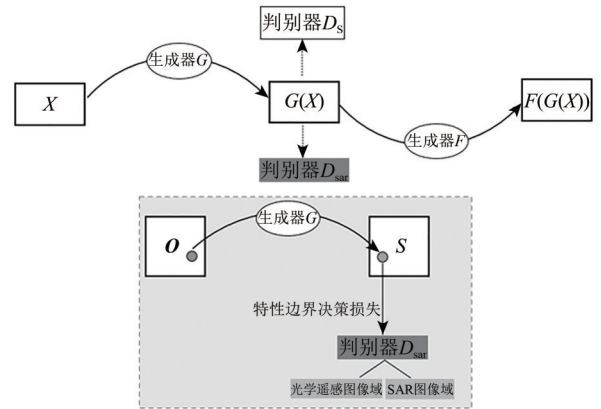
(a) 知识迁移网络结构图

(a) Knowledge transfer network structure diagram



(b) 恒等损失

(b) Identity loss



(c) 特征边界决策损失

(c) Feature boundary decision loss

图2 知识迁移网络

Fig. 2 Knowledge transfer network

2.2 恒等损失

在生成模拟图像的过程中, 不仅希望通过循环跨域变换后图像的特征分布不变 ($F(G(x)) \approx x$), 同时还希望 SAR 图像通过自身域映射函数 G 映射后仍然具有与 SAR 图像相似的特征分布, 即 $y \rightarrow G(y) \approx y$, 域映射函数能够在转化过程中尽可

能多的保持该 SAR 图像域的特征分布。因此, 本文提出使用恒等损失 (图 2(b)) 来约束映射函数 G 使输入 SAR 图像所生成模拟图像的特征分布与 SAR 图像特征分布尽可能相似。同时, 也使映射函数更具鲁棒性, 适应更多样的输入数据 (Taigman 等, 2017)。具体来说, 一个真实 SAR 图像 y , 经过映射函数进行转换后得到的样本应该与图像 y 尽可能一致:

$$L_{\text{identity}}(G) = E_{y \sim p_{\text{sar}}(y)} (\|G(y) - y\|_1) \quad (4)$$

2.3 特征边界决策损失

为了使 $G(x)$ 所生成的模拟图像尽可能接近 SAR 图像特征分布, 同时区别于光学图像, 本文在映射函数 G 学习的过程中使用特征判别器 D_{sar} (图 2(c)), 判断 G 生成的模拟图像特征分布更接近光学遥感图像还是 SAR 图像。通过 D_{sar} 约束生成的模拟图像使之和 SAR 图像更为“一致”, 并惩罚那些特征分布更类似于光学遥感图像的生成样本。因此, 特征边界决策损失函数为

$$L_{D_{\text{sar}}} = E_{x \sim p_{\text{opt}}(x)} (\log(1 - D_{\text{sar}}(G(x)))) + E_{y \sim p_{\text{sar}}(y)} (\log D_{\text{sar}}(y)) \quad (5)$$

特征判别器 D_{sar} 的输出为向量 $[p1, p2]$, 其中 $p1$ 表示 G 生成的模拟图像与 SAR 图像域特征分布相似的置信度, $p2$ 为与光学遥感图像域特征分布相似的置信度。置信度较大的图像域为判别器输出的分类结果, 即 SAR 图像或非 SAR 图像。例如, 若图像在 D_{sar} 上的结果为 $[0.9, 0.1]$, 则认为这个样本更接近于 SAR 图像特征分布。然而, 如果当生成图像的特征不具有显著区分性, D_{sar} 将会输出类似于 $[0.5, 0.5]$ 的模糊判决结果。为了增加特征的区分性, 也就是希望特征决策边界能够更好地区别 SAR 图像与光学遥感图像特征分布, 我们使用特征边界决策损失来增强特征的区分性, 通过计算 D_{sar} 与 $[0.5, 0.5]$ 之间的交叉熵:

$$L_{\text{boundary}}(D_{\text{sar}}) = \sum_{k \in \{\text{SAR}, \text{OPTICAL}\}} \frac{\log D_{\text{sar}}(G(x))_{c=k}}{2} \quad (6)$$

$c = k$ 表示 $G(x)$ 可能的类别, 即 SAR 图像域和光学遥感 (OPTICAL) 图像域。 $D_{\text{sar}}(G(x))_{c=k}$ 表示判别器的输出, 用来预测 G 生成的模拟图像属于 SAR 图像域或光学遥感图像域的置信度。通过最小化 L_{boundary} 可以将 G 生成的模拟图像特征分布与光

学遥感图像特征分布的决策边界最大化。

2.4 整体损失函数表示

综上所述, 本文使用循环一致生成对抗损失, 恒等损失加强生成的模拟图像与 SAR 域图像的特征相似性; 使用特征边界决策损失来抑制生成特征的混淆问题。综合式(1)–(4)、(6), 可得总体损失函数:

$$L(G, F, D_s, D_o, D_{\text{sar}}) = L_{\text{GAN}}(G, D_s, O, S) + L_{\text{GAN}}(F, D_o, S, O) + \lambda L_{\text{cyc}}(G, F) + \beta L_{\text{identity}}(G, F) - \alpha L_{\text{boundary}}(G, D_{\text{sar}}) \quad (7)$$

式中, 权重 λ , β 和 α 用以权衡各损失函数对最终生成结果的影响程度。

目标函数:

$$G^*, F^* = \arg \min_{G, F} \max_{D_o, D_s, D_{\text{sar}}} L(G, F, D_o, D_s, D_{\text{sar}}) \quad (8)$$

式中, G^* , F^* 为希望求解的最优映射, 固定生成映射函数 G , F , 优化判别器 D_o , D_s , D_{sar} 使 L 最大, 即使前两个判别器尽可能区分真实图像与映射函数生成的图像, 同时判别器 D_{sar} 最大化映射函数 G 生成的模拟图像与 SAR 图像的特征相似性。接着再求使得 L 最小的 G , F , 即固定判别器 D_o , D_s , D_{sar} , 尽量使两个映射函数生成的图像接近真实图像, 并使得生成的图像能够尽可能地映射到原域。

2.5 网络结构

映射函数网络使用卷积和转置卷积实现特征图的下采样和上采样, 包含 4 个卷积层, 9 个残差块 (He 等, 2016) (包括两个卷积核为 3×3 , 步长为 1 的卷积层和残差连接), 2 个转置卷积层, 最后输出与输入图像尺寸一致的生成图像。判别器网络使用 70×70 PatchGANs (Isola 等, 2017), 网络完全由卷积层构成, 用来判断生成图片中 70×70 patch 是“生成的”还是“真实的”。特征判别器网络结构包括一个 7×7 的卷积层, 和 4 个残差块, 残差块包括 1 个卷积核为 3×3 , 步长为 1 的卷积层, 1 个卷积核为 3×3 , 步长为 2 的卷积层和残差连接, 最后使用全连接层整合图像的特征信息得到判别结果。

3 舰船检测网络

基于优化式(8), 只需要获得具有标注的光学遥感图像样本, 就可以得到增广的带标注模拟图像数据集, 弥补了基于深度学习的目标检测网络

对于标注样本的需求也解决了数据域适应性的问题。

主流的基于深度学习目标检测算法可分为单阶段 (one-stage) 目标检测和两阶段 (two-stage) 目标检测。单阶段目标检测算法是基于回归的算法, 使用主干网络提取特征, 将目标分类和位置回归作为整体来处理, 网络直接预测图像中感兴趣区域的类别和位置坐标。此算法目标识别精度略低, 但是速度快, 代表性算法包括 YOLOv1 (Redmon 等, 2016), YOLOv2 (Redmon 和 Farhadi, 2017), YOLOv3 (Redmon 和 Farhadi, 2018), SSD (Liu 等, 2016) 等。两阶段目标检测算法是基于候选区域的算法, 首先由区域提议算法生成一系列的候选区域, 使用主干网络提取候选区域的特征, 再将提取到的特征送入分类网络和预测框回归网络进行分类和目标定位, 从而确定图像中感兴趣区域的类别和位置坐标。此类型目标检测算法的识别精度高, 但是速度慢, 难以满足实时性需求, 代表性算法 R-CNN (Girshick 等, 2014)、Fast R-CNN (Girshick, 2015)、Faster R-CNN (Ren 等, 2017) 等。需要特别说明的是, 本文提出模拟图像生成方法可以用于目前主流目标检测网络的训练数据集构建工作中。

本文使用 YOLOv3 作为 SAR 图像舰船检测网络 (图 1 右侧网络)。YOLOv3 使用一种新的骨干网络 Darknet-53 用于图像特征提取, 该网络借鉴了深度残差网络 ResNet (Deep residual network) (He 等, 2016) 的做法, 在残差结构中使用了 Shortcut

Connections (He 等, 2016) 来连接残差结构中的不同层, 从而有效抑制深层网络中的梯度弥散问题。YOLOv3 作为单阶段 (one-stage) 目标检测网络, 通过改变网络结构的复杂程度来权衡速度与精度。YOLOv3 采用多尺度特征图思想, 在 3 个不同尺度特征图上提取特征, 使用基于训练集标注框上聚类出的 9 个不同大小的锚点框, 来适应不同尺寸的目标, 因此 YOLOv3 在不同尺寸的舰船目标检测中表现较好。

4 结果与分析

4.1 数据集及实验环境

为了验证本文提出方法有效性, 本研究在 4 个数据集上进行了实验, 分别为 SEN1-2 (Schmitt 等, 2018) (图 3 第 1, 2 行), DIOR (Li 等, 2020) (图 4 第 1 行), SSDD (Li 等, 2017) (图 5 第 1 行), AIR-SARShip-1.0 (孙显 等, 2019) (图 6 第 1 行)。数据集详细信息见表 1。其中对于 SEN1-2 数据集, 包含 282384 对呈对应关系的光学遥感图像与 SAR 图像, 随机挑选了 2047 对作为知识迁移网络的训练集。DIOR 数据集是光学遥感图像数据集, 包含 20 个类别, 在含有舰船类别的图像中随机挑选了 876 张。SSDD 数据集包含 1160 张图像, 划分训练集和测试集的比例为 7 : 3。AIR-SARShip-1.0 数据集包含 31 幅 3000×3000 的大图, 实验中将其按网络需求裁剪为含有舰船目标的小尺寸图像, 划分训练集和测试集的比例为 7 : 3。




图 3 SEN1-2 数据集样例与知识迁移网络生成的模拟图像样例

Fig. 3 Example of the SEN1-2 dataset and simulated image samples generated by the knowledge transfer network in this paper




图4 DIOR 光学图像样例与知识迁移网络生成的模拟图像样例

Fig. 4 DIOR optical image examples and pseudo-SAR image samples generated by the knowledge transfer network




图5 不同方法在SSDD测试集样例上检测结果

Fig. 5 Detection results of different methods on the SSDD test set examples




图6 不同方法在Air-Sar-Ship1.0测试集样例上检测结果

Fig. 6 Detection results of different methods on the Air-Sar-Ship1.0 test set examples

实验运行环境见表2。在训练知识迁移网络时，所有子网络使用Adam优化器进行优化，初始学习率为0.0002，总共迭代训练200次，总体损失函数中权重 λ ， β 和 α 分别为10，0.5，0.5。舰船检测网络使用YOLOv3在ImageNet数据集上的预训练模型，网络使用Adam优化器进行优化，初始学习率为0.01，动量为0.9，衰减率为0.0005，迭代训练240次。

4.2 评价指标

目标检测性能使用平均准确率AP (Average precision) 进行度量：

$$AP = \sum_{r=0}^1 (r_{n+1} - r_n) p_{\text{interp}}(r_{n+1}) \quad (9)$$

式中， $p_{\text{interp}}(r_{n+1})$ 计算方式如下所示：

$$p_{\text{interp}}(r_{n+1}) = \max_{\tilde{F} \geq r_{n+1}} p(\tilde{r}) \quad (10)$$

式中， $p(\tilde{r})$ 代表在召回率下最大的准确率。

表1 数据集详细信息

Table1 Datasets details

数据参数	SEN1-2	DIOR	SSDD	AIR-SARShip-1.0
数据类型	光学遥感,SAR	光学遥感	SAR	SAR
数据生成阶段	√	√	×	×
目标检测阶段	×	√	√	√
来源	Sentinel-1, Sentinel-2	Google Earth	RadarSat-2, TerraSAR-X 和 Sentinel-1	高分三号卫星
分辨率	10 m	0.5—30 m	1—15 m	1 m/3 m
总数量	282384对	23463张	1160张	31张
图像尺寸	256×256	800×800	500×500	3000×3000

表2 实验运行环境

Table 2 Runtime environment of our experiment

类别	环境条件
CPU	Inter(R) Core(TM) i7-8700
显卡	GeForce GTX 2080Ti
内存	8G
操作系统	Ubuntu18.04
深度学习框架	Pytorch
CUDA版本	10.1
cuDNN版本	6.7
脚本语言	Python3.6

准确率 P 和召回率 γ 的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$\gamma = \frac{TP}{TP + FN} \quad (12)$$

式中, TP代表检测结果为正样本且真实值为正样本的预测框数量, FP代表检测结果为正样本但真实值为负样本的预测框数量, FN代表检测结果为负样本但真实值为正样本的预测框数量。

F1分数是对准确率和召回率的调和平均, 公式为:

$$F1 = 2 \times \frac{P \times \gamma}{P + \gamma} \quad (13)$$

F1综合了准确率和召回率的结果, 当F1较高时, 则说明模型或算法的效果比较理想。

4.3 实验分析

将从3个方面评价本文方法的有效性, 生成数据有效性评价, 知识迁移网络中损失函数有效性评价, 舰船检测网络有效性评价。

4.3.1 生成模拟图像有效性评价

如表3所示, 目标检测网络的训练数据为

SSDD数据集、本文知识迁移网络生成的模拟图像(图4第2行)时, 检测效果提升最为明显。使用70%的SSDD数据集中数据、本文知识迁移网络生成的模拟图像训练舰船检测网络, AP达到了97.50%。当使用SSDD数据集中0%, 10%, 20%, 30%, 50%的数据进行模型训练时, AP分别为64.55%, 91.14%, 94.69%, 96.21%, 96.84%, 均高于对比组实验结果。说明在知识迁移网络中使用循环一致生成对抗损失, 恒等损失, 特征边界决策损失, 生成的模拟图像, 使目标检测网络学习到更丰富的SAR图像特征信息, 提升网络的检测能力。

表3 使用不同比例SSDD的训练数据的检测结果

Table3 Detection performance of the ship detection network trained with different proportions of SSDD

比例	模拟图像	DIOR图像	DIOR灰度图	None	%
70	97.50	96.12	95.52	95.69	
50	96.84	95.33	95.37	94.82	
30	96.21	93.92	94.89	91.50	
20	94.69	93.60	93.29	86.74	
10	91.14	90.39	90.29	68.53	
0	64.55	49.84	41.00	—	

注: 加粗字体为本文方法检测结果。

由于本文知识迁移网络所生成的模拟图像在外观特征上与光学图像直接转换成的灰度图相似。本文使用DIOR数据集中光学遥感图像直接转换成灰度图作为训练数据(表3“DIOR灰度图”列), 进行实验对比。分别使用不同比例SSDD数据中数据、本文知识迁移网络生成的模拟图像, 和不同比例SSDD数据集中数据、DIOR灰度图来训练舰船检测模型, 实验结果表明本文生成的模拟图像

包含直接由光学图像转换成的灰度图像所不具有的特性，这些特性能够有效提升后续的目标检测模型的泛化性能。特别需要说明的是，从表3最后一行的结果可以看出，当不使用任何带有标注的SAR图像数据进行训练时，本文所生成的模拟图像训练得到的检测模型相比于由光学遥感图像和灰度图像上习得模型的AP值分别提高了14.71%和23.55%。这表明本文使用的迁移方法可以将光学图像域中的标注知识迁移至SAR图像域，同时使所习得的检测模型更适用于SAR图像域的舰船检测。

为评估本文知识迁移网络生成的模拟图像在不同数据集上对检测结果提升的有效性，使用SSD (Liu等, 2016), Faster R-CNN (Ren等, 2017)等目前较为流行的检测网络在SSDD和AIR-SARShip-1.0两个数据集上的检测结果进行对比。其中当目标检测网络为YOLOv3, Faster R-CNN时，输入的数据尺寸为500×500；当目标检测网络为SSD时，输入的数据尺寸为512×512。

表4中使用SSDD数据训练目标检测网络SSD, Faster R-CNN以及Dense Faster R-CNN (Jiao等, 2018)。其他方法均分别使用70%的SSDD数据集数据和AIR-SARShip-1.0数据集数据作为训练数据，并使用余下30%的数据作为测试集。实验结果表明，在不同目标检测网络中，本文生成的模拟图像在各项指标上均有较好的表现。说明本文知识迁移网络生成的模拟图像与SAR图像具有较为相似的特征分布，目标检测网络可以学习到更丰富的SAR舰船特征，从而提升目标检测的效果。

表4 使用不同数据集训练舰船检测网络的检测结果
Table 4 Detection performance of different ship detection networks trained with different datasets

		/%		
数据	方法	准确率	召回率	F1
SSDD	SSD	80.70	71.13	75.60
	YOLOv3	97.60	89.63	93.45
	Faster R-CNN	92.90	70.80	80.40
	Dense Faster R-CNN	96.70	83.40	89.60
	本文方法	98.87	90.67	94.59
Air-Sar-Ship1.0	SSD	85.49	74.41	79.57
	YOLOv3	90.27	74.71	81.76
	Faster R-CNN	83.11	72.57	77.46
	本文方法	95.09	89.59	92.26

注：加粗字体为本文方法检测结果。

使用Air-Sar-Ship1.0数据集进行实验，本文的方法相较于表中其他方法在准确率，召回率和F1均有较明显的提升。这是因为Air-Sar-Ship1.0数据集数据量较小，训练后的检测模型欠拟合。而使用本文知识迁移网络生成的模拟图像、Air-Sar-Ship1.0数据集中70%的数据作为训练集训练舰船检测网络，训练数据量增大，使得网络模型训练更加充分，训练后的模型更接近拟合，检测效果更优。

如图5，图6所示，第1行为标注框，第2行为训练集为SAR图像和光学遥感图像的检测网络的检测结果，第3行为训练集为SAR图像和模拟图像训练检测网络的检测结果。相较于海上，近海干扰物更多，场景更加复杂，给舰船检测带来了一定的困难。图5，图6中可以看出在近海区域SAR图像中，存在一些小亮斑区域，易被误检为舰船，而在岸边的真实舰船又会存在漏检的情况。本文知识迁移生成的模拟图像作为训练集训练舰船检测网络，使网络学习到更多SAR图像中舰船的特征，对漏检和误检均有一定程度的降低。

4.3.2 知识迁移网络中损失函数有效性评价

知识迁移网络不使用一致生成对抗损失时，网络难以收敛，生成的模拟图片效果较差。因此，为了验证本文知识迁移网络中恒等损失和特征边界决策损失的有效性，本节研究在知识迁移网络中使用循环一致生成对抗损失的基础上，再分别使用恒等损失和特征边界决策损失对生成的模拟图像的影响。如表5所示，在知识迁移网络中使用循环一致生成对抗损失的基础上，同时使用恒等损失，特征边界决策损失效果最优，AP提高了17.16%。而相比于分别使用恒等损失或特征边界决策损失，AP分别提高了6.38%和3%。说明本文方法，在提升目标检测精度上具有积极意义。

值得注意的是，特征边界决策损失比恒等损失可以更好的提高知识迁移网络中映射函数G的生成能力，进而提高目标检测网络的效果。主要因为特征边界决策损失约束生成的模拟图像拥有更多接近于SAR图像的特征，训练图像与测试图像数据特征分布越接近，训练图像对目标检测网络的训练效果越好。恒等损失在提高映射函数的生成能力的同时增强映射函数的鲁棒性。在对映射函数G训练的过程中，不仅使用光学图像域的数

据同时也使用SAR图像域的数据，以保证该函数在自映射的过程中仍然能最大程度的保持SAR图像数据的分布特性。

表5 知识迁移网络使用不同损失函数生成的模拟图像训练舰船检测网络的检测结果

Table 5 Detection performance of the ship detection network trained with simulated images the knowledge transfer network uses different loss functions generated

$L_{identity}$	$L_{boundary}$	AP
×	×	47.39%
√	×	58.17%
×	√	61.55%
√	√	64.55%

注：加粗字体为本文方法检测结果。

为了更好地评价本文所生成的模拟图像在特征上与SAR图像的相似性，我们使用卷积神经网络Resnet18对图像进行CNN特征提取，将网络Adaptivepool2d层输出（2048维）作为图像特征。同时，我们使用两类图像对应维度的差值来评价特征相似性。图7中，横轴为特征维度，纵轴为特征值。从图7中可以看出，所生成的模拟图像与SAR图像的CNN特征具有较好的相似性。因此，基于模拟图像的CNN特征进一步训练得到的基于深度卷积网络的目标检测模型能够很好地适用于SAR图像中的目标检测。




图7 模拟图像与SAR图像CNN特征相似性

Fig. 7 CNN features similarity between pseudo-SAR image and SAR image

4.3.3 舰船检测网络有效性评价

图8为使用SSDD数据集中70%的图像以及DIOR数据集作为训练数据，使用30%的SSDD数据集中数据作为测试数据所得的P-R曲线

(Precision-Recall Curve)。在本文知识迁移网络中使用循环一致生成对抗损失，恒等损失，映射函数 G 的生成能力得到提升，同时鲁棒性也得到了增强。使用了特征边界决策损失，加强对模拟图像中的SAR特征的生成能力，增大生成的模拟图像与光学遥感图像特征的差距，使生成的模拟图像更加接近SAR图像。因此，本文生成的模拟图像作为训练数据可以增加目标检测网络学习到更适用于SAR图像的参数，进而提升网络的检测效果。

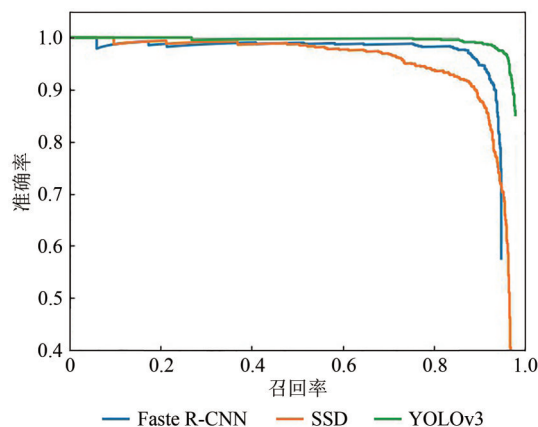


图8 不同检测网络上的检测结果的P-R曲线

Fig. 8 The P-R curve of detection performance on different detection networks

5 结论

本文提出一种基于生成式知识迁移的SAR舰船目标检测框架。在该框架下，首先构建一个知识迁移网络，通过提出使用循环一致生成对抗损失、恒等损失和特征边界决策损失进行约束，生成与SAR图像特征分布相似且与有标注的光学遥感图像空间分布一致的模拟图像。利用这些图像训练目标检测网络，以获得适用于SAR图像域的目标检测模型。在公开数据集上的实验结果表明，在只有少量甚至没有带标注的SAR图像的情况下，本文方法所生成的模拟图像，可以训练出泛化性能较好的目标检测模型，对复杂环境中的目标检测效果提升较为明显。后续工作将继续挖掘所生成的图像中的SAR特征，以提高在包含大量小目标SAR图像中的目标检测准确率。

参考文献(References)

Beltramonte T, Braca P, Bisceglie M D, Simone A D, Galdi C, Iodice

- A, Millefiori L M, Riccio D and Willett P. 2020. Simulation-based feasibility analysis of ship detection using GNSS-R delay-Doppler maps. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 1385-1399 [DOI: 10.1109/jstars.2020.2970221]
- Bochkovskiy A, Wang C Y and Liao H Y M. 2020. YOLOv4: optimal speed and accuracy of object detection. *arXiv preprint arXiv: 2004.10934* [DOI: 10.48550/arXiv.2004.10934]
- Choi Y, Uh Y, Yoo J and Ha J W. 2020. StarGAN v2: diverse image synthesis for multiple domains//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE: 8185-8194 [DOI: 10.1109/cvpr42600.2020.00821]
- Demars C D, Roggemann M C and Havens T C. 2015. Multispectral detection and tracking of multiple moving targets in cluttered urban environments. *Optical Engineering*, 54(12): 123106 [DOI: 10.1117/1.oe.54.12.123106]
- Girshick R. 2015. Fast R-CNN//2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE: 1440-1448 [DOI: 10.1109/iccv.2015.169]
- Girshick R, Donahue J, Darrell T and Malik J. 2014. Rich feature hierarchies for accurate object detection and semantic segmentation//2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE: 580-587 [DOI: 10.1109/CVPR.2014.81]
- Gui Y C, Li X H and Xue L. 2019. A multilayer fusion light-head detector for SAR ship detection. *Sensors*, 19(5): 1124 [DOI: 10.3390/s19051124]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE: 770-778 [DOI: 10.1109/cvpr.2016.90]
- Isola P, Zhu J Y, Zhou T H and Efros A A. 2017. Image-to-image translation with conditional adversarial networks//2017 IEEE Conference on Computer Vision and Pattern Recognition. Hawaii: IEEE: 5967-5976 [DOI: 10.1109/cvpr.2017.632]
- Jiao J, Zhang Y, Sun H, Yang X, Gao X, Hong W, Fu K and Sun X. 2018. A densely connected end-to-end neural network for multi-scale and multiscale SAR ship detection. *IEEE Access*, 6: 20881-20892 [DOI: 10.1109/access.2018.2825376]
- Li J J, Jing M M, Lu K, Zhu L, Yang Y and Huang Z. 2019. Alleviating feature confusion for generative zero-shot learning//27th ACM International Conference on Multimedia. Nice: Association for Computing Machinery: 1587-1595 [DOI: 10.1145/3343031.3350901]
- Li J W, Qu C W and Shao J Q. 2017. Ship detection in SAR images based on an improved faster R-CNN//2017 SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA). Beijing: IEEE: 1-6 [DOI: 10.1109/bigсарdata.2017.8124934]
- Li K, Wan G, Cheng G, Meng L Q and Han J W. 2020. Object detection in optical remote sensing images: a survey and a new benchmark. *ISPRS Journal of Photogrammetry and Remote Sensing*, 159: 296-307 [DOI: 10.1016/j.isprsjprs.2019.11.023]
- Li Z L, Wang L Y, Jiang S, Wu Y H and Zhang Q J. 2021. On orbit extraction method of ship target in SAR images based on ultra-light weight network. *National Remote Sensing Bulletin*, 25(3): 765-775 (李宗凌, 汪路元, 蒋帅, 吴雨航, 张庆君. 2021. 超轻量网络的SAR图像舰船目标在轨提取. *遥感学报*, 25(3): 765-775) [DOI: 10.11834/jrs.20210160]
- Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C Y and Berg A C. 2016. SSD: single shot MultiBox detector//14th European Conference on Computer Vision. Amsterdam: Springer: 21-37 [DOI: 10.1007/978-3-319-46448-0_2]
- Ma W, Chen D K, Yang N and Ma C. 2018. Time-series approach to estimate the soil moisture of a subsidence area by using dual polarimetric radar data. *Journal of Remote Sensing*, 22(3): 521-534 (马威, 陈登魁, 杨娜, 马超. 2018. 时序双极化SAR开采沉降区土壤水分估计. *遥感学报*, 22(3): 521-534) [DOI: 10.11834/jrs.20187259]
- Pan S J and Yang Q. 2010. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10): 1345-1359 [DOI: 10.1109/tkde.2009.191]
- Redmon J, Divvala S, Girshick R and Farhadi A. 2016. You only look once: unified, real-time object detection//Computer Vision and Pattern Recognition. Las Vegas: IEEE: 779-788 [DOI: 10.1109/CVPR.2016.91]
- Redmon J and Farhadi A. 2017. YOLO9000: better, faster, stronger//Computer Vision and Pattern Recognition. Honolulu: IEEE: 6517-6525 [DOI: 10.1109/CVPR.2017.690]
- Redmon J and Farhadi A. 2018. YOLOv3: an incremental improvement. *arXiv preprint arXiv: 1804.02767* [DOI: 10.48550/arXiv.1804.02767]
- Ren S Q, He K M, Girshick R and Sun J. 2017. Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137-1149 [DOI: 10.1109/tpami.2016.2577031]
- Schmitt M, Hughes L H and Zhu X X. 2018. The SEN1-2 dataset for deep learning in SAR-optical data fusion. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-1: 141-146 [DOI: 10.5194/isprs-annals-IV-1-141-2018]
- Sun X, Wang Z R, Sun Y R, Diao W H, Zhang Y and Fu K. 2019. AIR-SARShip-1.0: high-resolution SAR ship detection dataset. *Journal of Radars*, 8(6): 852-862 (孙显, 王智睿, 孙元睿, 刁文辉, 张跃, 付琨. 2019. AIR-SARShip-1.0: 高分辨率SAR舰船检测数据集. *雷达学报*, 8(6): 852-862) [DOI: 10.12000/JR19097]
- Taigman Y, Polyak A and Wolf L. 2017. Unsupervised cross-domain image generation//5th International Conference on Learning Representations. Toulon: OpenReview.net
- Wang C, Zhang H, Wu F, Jiang S F, Zhang B and Tang Y X. 2014. A novel hierarchical ship classifier for COSMO-SkyMed SAR data. *IEEE Geoscience and Remote Sensing Letters*, 11(2): 484-488 [DOI: 10.1109/lgrs.2013.2268875]
- Wang Y H and Liu H W. 2015. PolSAR ship detection based on super-pixel-level scattering mechanism distribution features. *IEEE Geoscience and Remote Sensing Letters*, 12(8): 1780-1784 [DOI: 10.1109/lgrs.2015.2425873]
- Xie X Y, Xu Q Z and Hu L. 2016. Fast ship detection from optical satellite images based on ship distribution probability analysis//4th International Workshop on Earth Observation and Remote Sens-

- ing Applications (EORSA). Guangzhou: IEEE: 97-101. [DOI: 10.1109/eorsa.2016.7552774]
- Xu F and Liu J H. 2016. Ship detection and extraction using visual saliency and histogram of oriented gradient. *Optoelectronics Letters*, 12(6): 473-477 [DOI: 10.1007/s11801-016-6179-y]
- Zhang J F, Zhang P, Wang M C and Liu T. 2019. CFAR detection method of polarimetric SAR imagery based on whitening filter under G_0 distribution. *Journal of Remote Sensing*, 23(3): 443-455 (张嘉峰, 张鹏, 王明春, 刘涛). 2019. G_0 分布下基于白化滤波的极化 SAR 图像 CFAR 检测. *遥感学报*, 23(3): 443-455 [DOI: 10.11834/jrs.20197431]
- Zhang T W and Zhang X L. 2019. High-speed ship detection in SAR images based on a grid convolutional neural network. *Remote Sensing*, 11(10): 1206 [DOI: 10.3390/rs11101206]
- Zhu J Y, Park T, Isola P and Efros A A. 2017. Unpaired image-to-image translation using cycle-consistent adversarial networks//2017 IEEE International Conference on Computer Vision. Venice: IEEE: 2242-2251 [DOI: 10.1109/iccv.2017.244]

SAR ship detection through generative knowledge transfer

LOU Xin, WANG Han, LU Hao, ZHANG Wenchi

1. *Beijing Forestry University, Beijing 100083, China;*
2. *Engineering Research Center for Forestry-oriented Intelligent Information Processing, National Forestry and Grassland Administration, Beijing 100083, China*

Abstract: To address data acquisition and labeling data in the training process of SAR ship-detection network based on deep convolutional neural network, we propose a SAR ship-detection framework via generative knowledge transfer of a knowledge transfer network for SAR image generation and a SAR ship-detection network. The knowledge transfer network consists of three parts: a cycle consistency GAN to synthesize virtual features which have spatial distribution of optical image domain and feature distribution of SAR image domain as well; We further use an identity loss to encourage pseudo-SAR images generated by the knowledge transfer networks to have more of the intrinsic features of SAR images. To alleviate the SAR feature confusion issue, we introduce a feature boundary decision loss to maximize the decision boundary of real SAR features and the pseudo ones. Therefore The knowledge transfer network generates pseudo-SAR images consistent with the spatial distribution of labeled optical remote-sensing images and has a feature distribution similar to those of SAR images. Our proposed method is evaluated from three aspects: (1) The evaluation on the generated pseudo-SAR images. When the object detection network is trained on 70% of SSDD and the pseudo-SAR images, The remaining 30% of SSDD is test set, the AP can reaches 97.50%. As for 0%, 10%, 20%, 30%, and 50% of SSDD, the AP is 64.55%, 91.14%, 94.69%, 96.21%, and 96.84%, respectively. When there is no real SAR images involved in the training process, Ap can still reach 64.55%. (2) Ablation study on loss functions. On the basis of using cycle consistency loss in knowledge transfer network, the best performance comes when applying both the identity loss and the feature boundary decision loss, the AP reaches 64.55%. (3) The evaluation on the ship detection network. The generated pseudo-SAR images in this paper are used in the training process of SSD, Faster R-CNN and YOLOv3 detection networks, which can increase the object detection network to learn more parameters suitable for SAR images, thus improving the detection effect of the network. Experiments in the above three aspects prove the effectiveness of the proposed method.

Key words: SAR, object detection, deep learning, image generation, generative adversarial networks

Supported by The Fundamental Research Funds for the Central Universities (No. QNTD202308)