基于深度学习的雷达图像目标识别研究进展

潘宗序^{1,2,3*}, 安全智^{1,2,3}, 张冰尘^{1,2,3}

1. 中国科学院电子学研究所, 北京 100190

2. 中国科学院空间信息处理与应用系统技术重点实验室, 北京 100190

3. 中国科学院大学, 北京 101408

* 通信作者. E-mail: zxpan@mail.ie.ac.cn

收稿日期: 2019-05-08; 接受日期: 2019-06-12; 网络出版日期: 2019-12-10

国家自然科学基金 (批准号: 61701478) 资助项目

摘要 雷达探测是一种有效的对地观测手段, 雷达图像目标识别是其重要研究方向. 深度学习已在众多领域取得成功, 然而训练深层神经网络需要大量数据, 样本量不足已成为制约深度学习在雷达图像目标识别中应用的主要因素. 本文对基于深度学习的雷达图像目标识别研究进展进行了综述, 梳理和总结了具有代表性的方法. 首先, 介绍针对雷达图像目标识别的数据扩充和网络模型设计方法. 然后, 详细阐述本课题组针对小样本条件提出的基于迁移学习、度量学习和半监督学习的雷达图像目标识别方法. 最后, 讨论了目前仍然存在的问题, 并给出了对未来发展趋势的展望.

关键词 雷达图像, 目标识别, 深度学习, 卷积神经网络, 小样本

1 引言

雷达是一种利用微波进行主动感知的传感器, 合成孔径雷达 (synthetic aperture radar, SAR) 利用合成孔径原理, 实现高分辨率的微波成像, 与光学、红外等传感器相比, 合成孔径雷达不受天气、光照等条件影响, 具有全天时、全天候、大幅宽、高分辨率等特点, 已成为对地观测的重要手段. 随着雷达数据收集能力的不断提升, 对雷达数据的自动解译得到了广泛的关注, 雷达目标识别则是其中的一个重要研究方向. 由于合成孔径雷达能够实现高分辨率成像, 因而雷达目标识别的研究大多是在 SAR 图像上开展的. SAR 自动目标识别 (automatic target recognition, ATR) 系统包含检测、鉴别和识别 3 个阶段^[1]. 检测阶段在 SAR 图像中提取感兴趣区域 (region of interest, ROI), 传统方法中最为常用的是恒虚警率 (constant false alarm rate, CFAR) 检测器^[2,3], 近年来深层神经网络被用来解决 SAR 目标

引用格式: 潘宗序, 安全智, 张冰尘. 基于深度学习的雷达图像目标识别研究进展. 中国科学: 信息科学, 2019, 49: 1626–1639, doi: 10.1360/SSI-2019-0093
Pan Z X, An Q Z, Zhang B C. Progress of deep learning-based target recognition in radar images (in Chinese). Sci Sin Inform, 2019, 49: 1626–1639, doi: 10.1360/SSI-2019-0093

检测问题并在性能上取得了显著的提升^[4~6],例如,Kang等^[4]通过融合多层特征提升检测性能.Liu等^[5]采用带有旋转框的神经网络检测器实现对近岸船只的检测.An等^[6]从先验框生成、旋转框编解码、多层特征融合、损失函数设计等方面入手对旋转框检测器进行了改进,并分析了各改进方式对检测性能的影响;鉴别阶段在ROI中滤除仅包含自然杂波的虚警;识别阶段给出目标的类型.SAR ATR系统涉及检测、鉴别、识别等多种技术,本文聚焦于对识别方法的讨论,即从SAR图像的ROI中识别目标的类型.

SAR目标识别的难点主要体现在以下3个方面^[7]:(1)目标本身的变化,同一类型的目标可能存在差异,例如结构和连接的变体和目标损坏导致的变体;(2)目标周围环境的影响,包括遮挡、层叠、隐蔽、伪装、电子对抗、电磁干扰等;(3)成像参数的影响,包括俯仰角、所用频率、成像模式、极化方式、视数、信噪比、分辨率等.上述影响因素使得SAR目标识别是一个非常复杂的问题,传统方法主要从特征提取和分类器设计两方面入手解决SAR目标识别问题.典型的SAR目标特征包括Gabor特征^[8]、阴影特征^[9]、散射点密度特征^[10]、显著点特征^[11]、散射簇特征^[12]等,用于SAR目标识别的常用分类器包括支持向量机分类器^[13]、基于模糊逻辑决策规则的分类器^[14]、基于图模型的分类器^[15]、基于非负矩阵分解的分类器^[16]、基于稀疏表示的分类器^[17,18]、基于流形学习的分类器^[19~21]等.

近年来,随着深度学习理论不断发展,相关方法已在众多领域取得突破性进展.卷积神经网络(convolutional neural network, CNN)是深度学习中最常用的模型,已成为图像分类领域中的主流方法.在2012年,Krizhevsky等^[22]采用深层卷积神经网络将大规模视觉挑战赛(ImageNet large scale visual recognition challenge, ILSVRC)中图像分类问题中的前5项错误率降低到15.3%,远远优于以往的最佳水平.后续学者又提出了更深的网络,取得了更好的效果,例如,Szegedy等^[23]提出的包含22层的GoogLeNet将前5项错误率降低到6.67%,He等^[24]提出的包含152层的ResNet进一步将前5项错误率降低到3.57%.

虽然雷达图像目标识别与计算机视觉中的自然图像分类有着相同的目的,都是提取有效特征并确定图像类别,但是由于雷达图像与可见光图像在成像原理、波段、视角等方面有较大的差异^[25],因此在利用计算机视觉领域新方法解决雷达图像目标识别问题时,需要对这些差异性加以考虑和利用.深度学习技术在解决雷达图像目标识别问题时的优势主要体现在其通过数据自动学习有效特征提取方法的机制,由于雷达图像的散射机理较为复杂,人工设计用于雷达图像目标识别的有效特征具有一定的难度,利用深度学习方法提取到的特征有望在分类性能上显著超越人工设计的特征.深度学习技术在解决雷达图像目标识别问题时的难点主要体现在训练样本的缺乏,在小样本条件下直接训练深层神经网络会产生严重的过拟合问题而导致网络的泛化能力极具下降,样本量不足已成为制约深度学习技术在雷达图像目标识别中应用的主要因素.基于深度学习的雷达图像目标识别方法主要从数据扩充和模型优化两方面入手加以解决:数据扩充通过对抗学习、电磁仿真等手段生成新样本;模型优化利用迁移学习、度量学习、半监督学习等方法实现小样本条件下的网络模型优化.本文对基于深度学习的雷达图像目标识别研究进展进行了综述,梳理和总结了具有代表性的方法,并对本课题组针对小样本条件下的雷达图像目标识别问题所提出的基于迁移学习、度量学习和半监督学习的方法进行了重点阐述.

本文后续结构组织如下:第2节介绍雷达图像目标识别的常用数据集,第3节对面向雷达图像目标识别的数据扩充方法进行综述,第4节介绍面向雷达图像目标识别的网络结构设计方法,第5~7节阐述本课题组针对小样本条件下的雷达图像目标识别问题所采用的基于迁移学习、度量学习和半监督学习的方法,第8节总结全文,讨论目前仍然存在的问题并给出对未来发展趋势的展望.

2 雷达图像目标识别数据集

MSTAR 数据集^[26] 是美国国防高等研究计划署 (Defense Advanced Research Projects Agency, DARPA) 运动和静止目标获取与识别 (moving and stationary target acquisition and recognition, MSTAR) 项目中公开发布的数据集, 共包含 10 类车辆目标: BMP-2, BTR-70, T-72, BTR-60, 2S1, BRDM-2, D7, T-62, ZIL-131, ZSU-234. 数据由 X 波段合成孔径雷达传感器采集, 成像模式为聚束, 极化方式为 HH, 距离向和方位向的分辨率均为 0.3 m, 目标方位角覆盖 $0^{\circ}\sim 360^{\circ}$. 为了更全面地评估分类器的性能, MSTAR 数据集提供了两种操作条件, 即标准操作条件 (standard operating conditions, SOC) 和扩展操作条件 (extended operating conditions, EOC), 其中标准操作条件是指测试与训练图像中目标的型号相同, 仅成像俯仰角和目标方位角不同, 扩展操作条件是指测试与训练图像具有较大差异, 主要体现在成像俯仰角有较大的变化、目标外形配置有较大的变化、同一类目标具有不同的型号. 通常采用标准操作条件下的 10 类目标分类任务和扩展操作条件下的 4 类目标分类任务来测试算法的性能.

OpenSAR 数据集^[27] 由上海交通大学智能探测与识别实验室发布, 包含了常见种类的民船, 可作为 SAR 船只识别任务的基准数据集. OpenSAR 数据集中的船只源自 Sentinel-1 卫星获取的 41 幅 SAR 图像, 在制作数据集的过程中结合了自动识别系统 (automatic identification system, AIS) 信息, 场景包含上海、深圳、天津、横滨和新加坡 5 个港口, 数据集采用了地距检测 (ground range detected, GRD) 产品和单视复图像 (single look complex, SLC) 产品. 数据集包含 17 个类别的船只, 共有 11346 个船只切片, 不同种类的船只在数量上并不均衡, 绝大部分船只样本为货船, 有些类别的样本仅有几个.

3 面向雷达图像目标识别的数据扩充方法

数据扩充又称数据增强或数据增广, 是一种有效提升神经网络性能的手段, 被广泛用于深度学习方法中. 由于 SAR 目标对方位角较为敏感, 不同方位角下的目标特性可能具有较大的差异, 在光学图像目标识别中普遍采用的旋转扩充手段未必适用于 SAR 目标识别问题. 针对雷达图像目标识别如何进行有效的数据扩充是一项值得研究的课题, 近年来国内外学者对这一问题展开了研究, 并取得了一定的进展. Ding 等^[28] 讨论了平移、添加噪声和样本合成 3 种数据扩充方法的作用, 并验证了这 3 种方法的有效性, 在样本合成方法中, 为了生成具有特定方位角 θ 的样本, 在训练集中搜索方位角与 θ 最为接近的两个样本, 将这两个样本的加权组合作为合成样本. WagnerSA 通过弹性变形和仿射变换生成扩充数据以提升模型的鲁棒性^[29]. 生成对抗网络 (generative adversarial networks, GANs) 包含一个生成器和一个判别器, 通过生成器和判别器之间的对抗训练学习数据的分布信息, 从而具有生成新数据的能力^[30]. 将 GANs 生成的样本作为扩充数据用于分类器的训练具有很好的前景, 但由于 GANs 存在训练困难、稳定性不足、模式崩溃等问题, 通过对抗训练获取能够有效提升分类器性能的扩充样本是一项具有挑战性的课题. Guo 等^[31] 利用 GANs 生成 SAR 目标样本, 并通过杂波归一化解决由于噪声引起的模型训练困难问题. Bao 等^[32] 比较了多种 GANs 模型生成的 SAR 目标样本, 包括基于卷积神经网络的 DCGAN (deep convolutional generative adversarial networks)^[33]、基于权值裁剪的 WGAN (Wasserstein generative adversarial networks)^[34] 和基于梯度惩罚的 WGAN^[35]. Cui 等^[36] 利用基于梯度惩罚的 WGAN 生成扩充样本, 同时提出一种样本选取方法在生成样本中选取高质量且具有特定方位角的样本, 在 MSTAR 数据集的分类问题上验证了这种数据扩充方法的有效性.

利用电磁仿真生成新样本是 SAR 目标识别领域中的另一种数据扩充手段, 例如 RaySAR 方法^[37]

根据目标的三维模型利用射线追踪技术构建仿真样本. RaySAR 方法需要人为设定与目标相关的电磁参数, 仿真图像的质量在很大程度上取决于电磁参数的设置. 为了确定有效的电磁参数, Niu 等^[38]利用神经网络进行电磁仿真参数的回归预测, 其流程请参考文献 [38] 中的图 1. 在训练阶段, 根据经验设置一系列电磁仿真参数, 利用 RaySAR 仿真软件生成仿真图像, 将仿真图像作为输入, 电磁仿真参数作为输出训练神经网络; 在测试阶段, 将真实 SAR 目标输入到训练好的神经网络中, 此时网络的输出即为网络预测的最佳电磁仿真参数, 可用该组电磁仿真参数生成 SAR 仿真样本. 由于仿真样本与真实样本处于不同的数据域中, 直接将仿真样本作为扩充样本未必能够提升分类器的性能, Liu 等^[39]指出在 B52 和 B707 两类 SAR 飞机识别问题中仿真样本的加入不但没有提升分类器的性能反而使得识别率有所下降, 并将原因归结为 SAR 真实样本与仿真样本在图像域的差异. 针对这一问题, Liu 等采用循环生成对抗网络 CycleGAN^[40]实现仿真数据域与真实数据域之间的转换, CycleGAN 是一种非配对的域自适应学习方法, 能够实现不同数据域间图像的转换. 在利用 CycleGAN 进行仿真样本优化的方法中, 训练阶段用于构建仿真样本和真实样本间相互转换的生成网络, 测试阶段利用训练的生成网络将仿真样本转换为更接近真实样本的形式, 其原理图请参考文献 [39] 中的图 2. 真实 B52 飞机、仿真 B52 飞机, 以及经过 CycleGAN 转换后的仿真 B52 飞机的比较请参考文献 [39] 中的图 3, 由结果可知, 经过 CycleGAN 转换后的仿真样本更加接近真实样本. 采用不同数据扩充方法的混淆矩阵和识别率的比较请参考文献 [39] 中的表 2, 由结果可知, 在不加入扩充数据时的识别率为 88.8%, 直接将仿真样本作为扩充数据时的识别率仅为 82.3%, 将仿真样本经过 CycleGAN 转换后再作为扩充数据时的识别率为 98.1%, 这一结果表明了利用 CycleGAN 优化仿真样本对提升分类器性能的有效性.

4 面向雷达图像目标识别的网络结构设计

近年来国内外学者针对雷达图像目标识别问题, 设计了不同的神经网络模型来提高识别率. 在样本量不足条件下, 直接训练网络容易发生过拟合, 一种解决方案是先采用无监督学习方法构建用于提取特征的预训练模型, 再利用标签样本对网络参数进行调优, 这种方式能够有效地利用更多样本, 例如在文献 [41] 中受限玻尔兹曼机和多层自编码器用于构建特征提取网络; 在文献 [42] 中深层卷积神经网络被拆分成卷积自编码网络和浅层神经网络, 以无监督学习方式训练卷积自编码网络作为特征提取器, 包含全连接层的浅层神经网络则通过监督学习方式训练并作为预测目标类别的分类器; Geng 等^[43]也采用了卷积自编码网络, 此外方法通过进行尺度变换减小斑点噪声的影响, 利用形态学平滑操作移除分类图中的孤点; Bentes 等^[44]则采用去噪自编码器构建用于提取特征的预训练网络对 SAR 图像中的船只进行分类. 另一种解决方案是设计特定的网络结构来应对样本不足所带来的问题, 较有代表性的工作包括, 文献 [45] 采用小规模网络并通过去掉全连接层降低网络训练中的过拟合风险, 针对 MSTAR 数据集中的 10 类分类问题取得了 99% 的识别率; Lin 等^[46]采用高速路网络允许信息高速无阻碍地通过深层神经网络的各层, 有效地降低了梯度消失问题带来的影响. 卷积高速路网络基于门机制, 包含转换门和搬运门两种基本结构, 通过转换门对输入的一部分进行转换, 通过搬运门使另一部分直接通过, 所采用的网络层结构请参考文献 [46] 中的图 1. 文献 [46] 进一步通过集成两个具有不同卷积核尺寸的卷积高速路单元网络获取图像的多尺度特征表示, 从而提高方法的识别性能. 针对 MSTAR 数据集中的 10 类分类问题, 即使训练样本下降到原有数据量的 30%, 该方法仍然能够取得较好的识别效果; 文献 [47] 在卷积神经网络中引入记忆单元, 通过加入信息存储单元记录样本的空间特征, 并利用空间特征相似性推测未知样本的类别; Song 等^[48]提出一种基于零次学习的 SAR 目标识别方法, 其原理图请参考文献 [48] 中的图 1, 该方法从已知 SAR 图像中自动学习 SAR 目标特征的分

层次表示, 同时构建连续的 SAR 目标特征空间, 在该空间中目标的角度敏感性特征和角度不变性特征能够得到分离, 该特征空间由已知的目标样本张成, 并被用于解译未知类别的目标; 针对雷达高分辨率距离像 (high-resolution range profile, HRRP) 数据的识别问题, Xu 等^[49] 采用基于循环神经网络的注意力模型对隐藏在数据内部的目标结构信息加以利用; 文献 [50] 采用 t-SNE 方法解决 HRRP 目标识别中的训练数据不均衡问题, 利用判别式深层置信网络 (discriminant deep belief network, DDBN) 提取训练数据中与类别无关的全局特征来提升小样本条件下的分类性能。

利用多角度 SAR 图像进行目标识别^[51,52] 是近年来的一项研究热点, Zhang 等^[53] 通过双向长短期记忆 (long short-term memory, LSTM) 循环神经网络利用多角度图像对 SAR 目标进行分类, 方法的原理图请参考文献 [53] 中的图 1, 首先选取具有不同方位角的目标图像组成多角度目标图像序列, 然后采用 Gabor 滤波器提取特征并利用局部二值模式 (local binary pattern, LBP) 对特征进行编码, 接下来用一个浅层的神经网络对特征进行降维, 最后利用双向循环神经网络将多角度信息进行融合从而计算目标的类别. 实验结果表明, 方法在 MSTAR 数据集中的 10 分类问题上能够达到 99% 的识别率, 且具有更好的抗噪和抗混淆性能。

在极化 SAR 图像分类问题中, 为了更好地利用极化数据中的多通道信息, 文献 [54] 首先将极化协方差矩阵转换为六维特征向量, 再将其作为卷积神经网络的输入. 对于极化 SAR 或干涉 SAR 等多通道相干的 SAR 图像, 通道间的相干相位差包含对地物分类和目标识别重要的信息^[25], 文献 [55] 将卷积神经网络推广到复数域, 提出复数卷积神经网络, 将复数据作为输入, 网络中的各层对相位信息进行了传递, 其网络结构请参考文献 [55] 中的图 1, 在极化 SAR 图像分类问题上的结果表明复数卷积神经网络较常规实数卷积神经网络具有更优的分类性能. 文献 [56] 提出复数自编码网络解决极化 SAR 图像分类问题。

轻量化模型被引入到 SAR 目标识别中, 用以实现资源受限条件下的高速目标识别. Chen 等^[57] 首先采用剪枝和自适应结构压缩降低模型规模并提高训练和推断速度, 然后将权值进行量化和编码实现模型的进一步压缩, 方法在不损失分类精度的情况下实现了 40 倍的模型规模下降和 15 倍的运算量减少. 文献 [58] 通过将传统卷积分解为逐通道卷积和逐像素卷积的级联来降低运算量. Min 等^[59] 利用知识蒸馏^[60] 压缩 SAR 目标识别网络, 其核心思想是首先训练具有较大规模的教师网络, 然后利用蒸馏学习用教师网络的输出指导具有较小规模的学生网络, 从而实现网络模型的压缩, 在原有知识蒸馏方法的基础上, Min 等以渐进的方式进行蒸馏学习, 取得了更好的性能。

5 小样本条件下基于迁移学习的雷达图像目标识别方法

迁移学习是一种运用已有知识解决不同但相关领域问题的方法, 其目的是将源任务中的知识迁移到目标任务中, 关键是寻求源领域和目标领域的共有特征表示. 如何设计源任务以及如何进行迁移是基于迁移学习方法重点关注的问题. 文献 [61] 使用光学 CIFAR-10 数据集构建预训练网络并将网络的中间特征层用于 TerraSAR 图像的分类. Marmanis 等^[62] 指出由于光学和 SAR 数据具有较大的差异, 很难将由光学数据训练的网络直接用于 SAR 目标分类任务, 即使是低层网络特征也难以进行有效的迁移. Huang 等^[63] 使用与 SAR 目标较为接近的无标签 SAR 场景图像, 利用栈式卷积自编码网络通过无监督学习构建预训练模型, 并引入重建旁路提供正则化约束进一步提升迁移性能. 文献 [64] 通过利用仿真 SAR 图像构建预训练模型将知识由仿真数据迁移到真实数据上。

Huang 等^[65] 从 3 个方面讨论 SAR 目标分类中的迁移问题: (1) 选取何种网络和源数据; (2) 在哪个特征层进行迁移; (3) 如何进行有效的迁移. 得出以下结论: (1) 尽管小型网络在训练样本较少时能

够表现出不错的性能,但泛化能力较差,难以将其迁移到其他任务中,大型网络具有更优的迁移潜能;(2)源任务与目标任务越接近,迁移效果越好,光学数据集也有利于 SAR 目标分类任务的解决,但不能直接迁移,需要以一种传递的方式进行;(3)神经网络提取特征可分为一般性特征和特殊性特征,一般性特征与任务的关联性小,可直接用于其他任务,特殊性特征具有较强的任务关联性,仅适用于特定任务,在网络中靠前层特征表现出更强的一般性而靠后层特征则具有更强的特殊性,对于特定的源任务和目标任务,需要对网络特征中的一般性和特殊性进行分析以确定哪些层可直接进行迁移,哪些层需要进一步使用目标域数据进行参数调优;(4)在迁移过程中加入域自适应学习可有效拉近源域和目标域数据的距离,从而进一步提升迁移的性能.结合上述结论,Huang 等^[65]提出了基于多数据源传递式域自适应迁移模型.对目标任务 T ,假设选取 3 个源任务 S^i , S^j 和 S^n ,这 3 个源任务按照与目标任务的关联性由弱到强排列.利用这 3 个源任务进行多数据源任务传递式迁移学习的示意图请参考文献^[65]中的图 3.利用 S^i 训练数据构建网络 $N(S^i)$,设网络共有 L 层,为了分析由 S^i 迁移到 S^j 过程中 $N(S^i)$ 各层的一般性与特殊性.将 $N(S^i)$ 的前 k 层固定,对第 $k+1 \sim L$ 层的参数进行随机初始化并利用源任务 S^j 训练数据对参数进行更新,如果网络在源任务 S^j 测试集上的识别率优于直接利用源任务 S^j 训练数据所构建网络 $N(S^j)$ 的结果,则在将 S^i 迁移到 S^j 过程中 $N(S^i)$ 的第 k 层具有一般性,否则第 k 层具有特殊性.通过以上分析,可以确定在由一项任务迁移到另一项任务过程中,应该冻结哪些层,调优哪些层,将迁移后的网络记为 $N(S^i * S^j)$.通过类似的方式构建适用于目标任务 T 的网络 $N(S^i * S^j * S^n * T)$.Huang 等^[65]利用 OpenSAR 数据集验证多数据源传递式迁移学习方法的有效性,采用不同数目的数据源进行传递式迁移学习结果的比较请参考文献^[65]中的图 12,其中虚线为直接利用 OpenSAR 数据集进行训练的结果,并将其作为基准识别率,圆形点标注的线表示采用 ImageNet, SAR 和 MSTAR 3 种源数据进行传递式学习再迁移到 OpenSAR 数据集的结果,菱形、方形和三角形点标注的线具有类似的含义.由结果可知,采用更多的数据源能够取得更好的分类效果,与 SAR 图像差异较大的 ImageNet 光学图像也能通过传递式迁移学习帮助提升 SAR 目标识别的性能.此外,文献^[65]通过基于最小化源域与目标域数据的最大平均差异(maximum mean discrepancy, MMD)^[66]的域自适应学习方法进一步提升识别网络的性能.经过域自适应学习前后网络提取的源域数据和目标域数据特征的可视化结果比较请参考文献^[65]中的图 16,结果表明域自适应学习降低了源域与目标域数据在特征域的差异,文献^[65]指出域自适应学习的加入能够进一步提升迁移后网络的识别性能.

6 小样本条件下基于度量学习的雷达图像目标识别方法

度量学习是另一种解决小样本分类问题的方法,并已应用于 SAR 目标识别中^[67].对于包含 K 个训练样本的 M 类分类问题,度量学习方法将该问题转换为判断两个样本是否属于同一类别的二分类问题,将属于同一类的两个样本组合成正样本对,将属于不同类的两个样本组合成负样本对.正负样本对的总数目为 $K(K-1)/2$,相比原始数据集数据量扩充了 $(K-1)/2$ 倍.由于负样本对数目要远大于正样本对,通常会采用困难负样本挖掘^[68]选取那些易于判为同类目标的负样本对.Pan 等^[67]通过孪生卷积神经网络实现度量学习,并用来解决 SAR 目标识别问题.孪生卷积神经网络由结构相同权值共享的两个卷积神经网络构成,其结构图请参考文献^[67]中的图 1(a).对两个 SAR 目标样本 X_i 和 X_j ,首先利用孪生卷积神经网络提取特征,将特征向量记为 $G_W(X_i)$ 和 $G_W(X_j)$.然后通过下式计算两个样本在特征域的差异:

$$E_W = f_{\text{abs}}(G_W(X_i) - G_W(X_j)), \quad (1)$$

其中, $f_{\text{abs}}(\mathbf{x})$ 表示对向量 $\mathbf{x}$ 中的每个元素求取绝对值. 再通过全连接层将 $\mathbf{E}_W$ 转换为实数值 D_W , 将 D_W 作为样本 $\mathbf{X}_i$ 和 $\mathbf{X}_j$ 间的距离度量, 该过程可用下式加以描述:

$$D_W = \mathbf{W}_{\text{FC}}^T \mathbf{E}_W + b_{\text{FC}}, \quad (2)$$

其中, $\mathbf{W}_{\text{FC}}$ 和 b_{FC} 表示全连接层的权值和偏置参数. 最后, 通过激活函数层计算样本相似概率 P_W , 如下式所示:

$$P_W = f_{\text{sigmoid}}(C - D_W), \quad (3)$$

其中, f_{sigmoid} 为 sigmoid 函数, 被定义为 $f_{\text{sigmoid}}(z) = 1/(1 + e^{-z})$, C 为常数阈值. 在训练过程中, 通过最小化如下式所示的带有正则化项的交叉熵损失函数确定网络中的参数:

$$L_{\text{metric}} = -[l \log(P_W) + (1 - l) \log(1 - P_W)] + \lambda \|\mathbf{R}(\mathbf{W})\|_2^2, \quad (4)$$

其中, l 表示样本对的标签, 对于正样本对 l 为 1, 对于负样本对 l 为 0, $\|\mathbf{R}(\mathbf{W})\|_2^2$ 为正则化项, λ 为控制交叉熵损失项与正则化项权重的参数. 在测试阶段, 计算测试样本与每个训练样本的样本相似概率, 如果相似概率大于 0.5, 则判断测试样本与该训练样本属于同一类别, 否则判断为属于不同类别, 最后通过投票的方式确定测试样本的类别. 这种方式需要计算测试样本与每个训练样本的样本相似概率, 当训练集中样本数目较多时无法保证运算效率. 针对这一问题, Pan 等 [67] 将孪生卷积神经网络中的单支网络作为特征提取器, 并在单支网络的后面再训练一个分类网络, 由于经过孪生卷积神经网络同类样本具有较小的距离而非同类样本具有较大的距离, 因而仅需要构建一个较为简单的分类网络.

为了提升度量学习网络的性能, 可以进一步采用基于孪生卷积神经网络的多任务学习模型, 在度量两个样本相似度的基础上加入对两个样本进行分类的任务. 将样本 $\mathbf{X}_i$ 和 $\mathbf{X}_j$ 的分类交叉熵损失记为 $L_{\text{cls}_X_i}$ 和 $L_{\text{cls}_X_j}$, 则多任务学习模型的损失函数如下式所示:

$$L_{\text{total}} = L_{\text{cls}_X_i} + L_{\text{cls}_X_j} + \eta L_{\text{metric}}, \quad (5)$$

其中, η 为控制分类任务与相似性度量任务权重的参数. 针对 MSTAR 测试数据集中的十类目标, 孪生卷积神经网络所提取特征的 t-SNE 可视化 [50] 结果可参考文献 [67] 中的图 2, 从可视化结果可以看到, 普通卷积神经网络难以区分部分不同类别的样本, 孪生卷积神经网络对不同类别目标所提取的特征具有更好的区分性. 可视化结果表明, 基于孪生卷积神经网络的度量学习模型能够有效减小类内离散度、增大类间离散度, 形成聚类效应, 从而提升小样本条件下的分类器性能. 不同训练样本数目条件下孪生卷积神经网络方法与普通卷积神经网络方法的识别率比较请参考文献 [67] 中的表 1, 由结果可知, 当训练样本数目较少时, 孪生卷积神经网络方法要明显优于普通卷积神经网络方法.

7 小样本条件下基于半监督学习的雷达图像目标识别方法

半监督学习方法能够同时利用标记和未标记样本, 并通过未标记样本提升学习性能. 半监督学习的基本原理图请参考文献 [69] 中的图 1, 图中比较了利用监督学习和半监督学习获得的分类边界, 其中方形和三角形表示两类标记样本, 圆形表示未标记样本. 监督学习仅考虑标记样本, 所得到的分类边界如左图所示; 半监督学习同时考虑标记和未标记样本, 所得到的分类边界如右图所示. 从聚类的角度来看, 利用半监督学习所得到的分类边界更加合理, 这要归功于其同时利用标记和未标记样本, 从而更好地进行数据分布估计的机制.

图 1 (网络版彩图) 基于半监督生成对抗网络的目标识别模型结构

Figure 1 (Color online) Target recognition model architecture based on semi-supervised generative adversarial networks

半监督学习的关键是借助未标记样本对数据的分布进行更加准确的估计,生成对抗网络能够从训练样本中有效地估计数据的分布,因而可以利用生成对抗网络进行半监督学习^[70].半监督生成对抗网络通过生成对抗网络从未标记样本中学习数据分布,从而实现半监督分类,其模型结构如图1所示.与GANs的结构类似,半监督GANs也由一个生成器和一个判别器构成,只是其判别器的任务要更加复杂.对于一个 K 类分类问题,令 $\mathbf{x}$ 和 $\mathbf{z}$ 分别表示真实数据和噪声数据, y 表示真实数据的类别标签,其取值范围为 $1 \sim K$.为了利用未标记样本,在半监督GANs网络中增加一个新的分类标签 $y = K + 1$,对应生成器生成的假样本.判别器 D 的任务包括:(1)对于标记样本,输出其类别;(2)对于未标记样本,将其判为真数据,即输出的类别标签为 $1 \sim K$;(3)对于生成器生成的假样本,将其判为假数据,即输出的类别标签为 $K + 1$.生成器 G 的任务为生成令判别器 D 判为真数据的假样本.半监督GANs可以建模成以下的优化问题:

$$\min_G \max_D V(D, G) = \mathbb{E}_{\mathbf{x}, y \sim p_{\text{data}}(\mathbf{x}, y)} [\log p(y = k | \mathbf{x}, D)] + \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} [\log(1 - p(y = K + 1 | \mathbf{x}, D))] \\ + \mathbb{E}_{\mathbf{z} \sim p_{\mathbf{z}}(\mathbf{z})} [\log p(y = K + 1 | G(\mathbf{z}), D)]. \quad (6)$$

在训练过程中,每次迭代输入 m 个标记样本、 m 个未标记样本和 m 个噪声数据,并采用随机梯度下降算法最小化目标函数.将标记样本数据记为 $\mathbf{X}_l = [\mathbf{x}_l^1, \dots, \mathbf{x}_l^m]$,未标记样本记为 $\mathbf{X}_u = [\mathbf{x}_u^1, \dots, \mathbf{x}_u^m]$,噪声数据记为 $\mathbf{Z} = [\mathbf{z}^1, \dots, \mathbf{z}^m]$, $\mathbf{X}_l$ 的类别标签记为 $\mathbf{Y}_l = [\mathbf{y}_l^1, \dots, \mathbf{y}_l^m]$,这里采用独热码(one-hot)形式的类别标签.网络的损失包含生成器损失 G_L 和判别器损失 D_L 两部分.生成器损失 G_L 通过下式进行计算:

$$G_L = -\frac{1}{m} \sum_{i=1}^m \log(1 - R_l(D(G(\mathbf{z}^i))) + \epsilon), \quad (7)$$

其中, $R_l(\cdot)$ 表示提取输入向量中最后一个元素的运算, ϵ 为保证算法数值稳定性的较小正值. 判别器损失 D_L 包含监督损失 D_S 和无监督损失 D_U 两部分, 可以写成如下形式:

$$D_L = wD_S + D_U, \quad (8)$$

其中, w 为控制两部分损失权重的参数. 监督损失 D_S 按照下式进行计算:

$$D_S = \frac{1}{m} \sum_{i=1}^m H(\mathbf{y}_l^i, R_K(D(\mathbf{x}_l^i))), \quad (9)$$

其中, $H(\mathbf{p}, \mathbf{q})$ 为计算 $\mathbf{p}$ 和 $\mathbf{q}$ 交叉熵的函数, $R_K(\cdot)$ 表示将输入向量的前 K 个元素提取出来形成 K 维向量的运算. 无监督损失 D_U 按照下式进行计算:

$$D_U = D_U^U + D_U^F = -\frac{1}{m} \sum_{i=1}^m \log(1 - R_l(D(\mathbf{x}_u^i)) + \epsilon) - \frac{1}{m} \sum_{i=1}^m \log(R_l(D(G(\mathbf{z}^i))) + \epsilon), \quad (10)$$

其中, D_U^U 和 D_U^F 分别表示未标记样本和假样本产生的损失. 在训练过程中, 将 w 设置为随迭代次数逐渐减小的值, 即

$$D_L(t) = w(t)D_S(t) + D_U(t), \quad (11)$$

其中, t 为迭代次数. $w(t)$ 按照下式进行计算:

$$w(t) = w(0)\alpha^{\lfloor t/T \rfloor}, \quad (12)$$

其中, $\lfloor x \rfloor$ 表示向下取整操作. 将 w 进行衰减是为了使得在训练初期监督损失能够占有较大的比重, 而随着迭代次数的增加, 网络更侧重于非标记样本.

在 MSTAR 数据集上测试半监督生成对抗网络方法的性能, 图 2 给出了半监督生成对抗网络生成器在 0, 10000, 20000 次迭代后生成的样本, 在训练初期, 网络仅能生成类似噪声的样本, 随着迭代次数的增加, 生成器能够生成更逼真的样本, 表明其学习到了数据的分布. 表 1 比较了几种方法在不同条件下的识别率, 表中 SGraph 表示基于半监督学习的图方法^[71], CNN 表示不利用半监督学习的卷积神经网络方法, SSGANs 表示半监督生成对抗网络方法; SOC- n 表示在标准操作条件下, 每类标记样本为 n 个, 训练集中的其余样本为未标记样本, EOC 表示在扩展操作条件下, 每类标记样本为 10 个, 训练集中的其余样本为未标记样本. 由结果可知, 半监督生成对抗网络方法要优于传统的半监督学习方法和基于监督学习的卷积神经网络方法.

8 总结与展望

雷达图像目标识别是雷达探测领域中的重要研究方向, 深度学习在大量数据中自动学习有效的特征提取方法. 本文综述了基于深度学习的雷达图像目标识别方法, 总结了针对该问题的典型网络模型, 对小样本条件下基于数据扩充、迁移学习、度量学习和半监督学习的方法进行了详细阐述. 尽管在雷达图像目标识别领域, 深度学习方法已经有了广泛的应用, 然而仍然存在大量问题有待解决.

首先, 目前多数基于深度学习的雷达图像目标识别方法采用的是卷积神经网络, 一些研究结果表明卷积神经网络的鲁棒性存在一定的问题, 主要体现在: (1) 由于池化操作抛弃了位置信息, 使得目标部件的朝向和空间上的相对关系对卷积神经网络而言并不重要, 网络只关注目标部件的特征是否存在^[72], 然而目标部件的位置信息是有助于对目标进行分类的; (2) 卷积神经网络易受对抗样本的攻击,

图 2 生成器生成的样本

Figure 2 Samples generated from the generator. Generated samples after (a) 0 iterations, (b) 10000 iterations, and (c) 20000 iterations

表 1 不同方法识别率 (%) 比较

Table 1 Comparison of recognition rates (%) of various methods

	SOC-10	SOC-20	SOC-30	EOC
SGraph	56.45	69.86	72.49	62.90
CNN	70.76	81.36	87.34	70.89
SSGANs	85.65	89.86	93.07	75.50

对输入稍作修改, 就能让网络给出与原输出几乎背道而驰的预测结果, 一个小型的对抗图像块就能使目标对分类器隐身^[73]. 目标在雷达图像中的特性受目标自身变化、周围环境和成像参数等诸多因素影响, 本身就较为复杂, 如果分类器的鲁棒性不足, 则很难应用于实际场景中. 如何提升雷达图像目标识别网络的鲁棒性是未来的研究方向之一.

其次, 雷达图像与光学图像具有较大的差异, 在雷达图像信息提取和目标解译过程中, 对电磁散射机理的理解是至关重要的. 虽然目前存在一些将神经网络与电磁散射特性相结合进行目标识别的工作, 但如何进一步将电磁散射机理与深度学习结合起来, 如何有效地将目标电磁散射知识融入到神经网络中仍然需要进行更加深入的研究.

最后, 通常情况下雷达图像目标识别问题的可用样本量较少, 尽管针对小样本问题近年来提出了一些方法, 然而这些方法往往是利用一种或几种技术手段来解决小样本条件下的网络训练和优化问题, 针对雷达图像目标识别问题, 将各种小样本机器学习算法有机地结合起来形成一套行之有效的解决方案, 对方法的实用化具有重要的意义.

参考文献

- 1 Dudgeon D E, Lacoss R T. An overview of automatic target recognition. Lincoln Lab J, 1993, 6: 3–10
- 2 Pan Z X, Liu L, Qiu X L, et al. Fast vessel detection in Gaofen-3 SAR images with ultrafine strip-map mode. Sensors, 2017, 17: 1578
- 3 An Q Z, Pan Z X, You H J. Ship detection in Gaofen-3 SAR images based on sea clutter distribution analysis and deep convolutional neural network. Sensors, 2018, 18: 334
- 4 Kang M, Ji K F, Leng X G, et al. Contextual region-based convolutional neural network with multilayer fusion for SAR ship detection. Remote Sens, 2017, 9: 860
- 5 Liu L, Chen G W, Pan Z X, et al. Inshore ship detection in SAR images based on deep neural networks. In: Proceedings of IEEE International Geoscience and Remote Sensing Symposium, 2018. 25–28

- 6 An Q Z, Pan Z X, Liu L, et al. DRBox-v2: an improved detector with rotatable boxes for target detection in SAR images. *IEEE Trans Geosci Remote Sens*, 2019, 57: 8333–8349
- 7 Kuang G Y, Ji K F, Su Y, et al. A survey of researches on SAR ATR. *J Image Graph*, 2003, 8: 1115–1120 [匡纲要, 计科峰, 栗毅, 等. SAR 图像自动目标识别研究. *中国图像图形学报*, 2003, 8: 1115–1120]
- 8 Hu F M, Zhang P, Yang R L, et al. SAR target recognition based on Gabor filter and sub-block statistical feature. In: *Proceedings of IET International Radar Conference*, 2009
- 9 Papson S, Narayanan R M. Classification via the shadow region in SAR imagery. *IEEE Trans Aerosp Electron Syst*, 2012, 48: 969–980
- 10 Zhang H, Tian X J, Wang C, et al. Merchant vessel classification based on scattering component analysis for COSMO-SkyMed SAR images. *IEEE Geosci Remote Sens Lett*, 2013, 10: 1275–1279
- 11 Chen J H, Zhang B, Wang C. Backscattering feature analysis and recognition of civilian aircraft in TerraSAR-X images. *IEEE Geosci Remote Sens Lett*, 2015, 12: 796–800
- 12 Pan Z X, Qiu X L, Huang Z L, et al. Airplane recognition in TerraSAR-X images via scatter cluster extraction and reweighted sparse representation. *IEEE Geosci Remote Sens Lett*, 2017, 14: 112–116
- 13 Zhao Q, Principe J C. Support vector machines for SAR automatic target recognition. *IEEE Trans Aerosp Electron Syst*, 2001, 37: 643–654
- 14 Margarit G, Tabasco A. Ship classification in single-pol SAR images based on fuzzy logic. *IEEE Trans Geosci Remote Sens*, 2011, 49: 3129–3138
- 15 Srinivas U, Monga V, Raj R G. SAR automatic target recognition using discriminative graphical models. *IEEE Trans Aerosp Electron Syst*, 2014, 50: 591–606
- 16 Cui Z Y, Cao Z J, Yang J Y, et al. SAR target recognition using nonnegative matrix factorization with $L_{1/2}$ constraint. In: *Proceedings of IEEE Radar Conference*, 2014. 382–386
- 17 Dong G G, Kuang G Y, Wang N, et al. SAR target recognition via joint sparse representation of monogenic signal. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2015, 8: 3316–3328
- 18 Pan Z X, Liu L, Lei B. Identity regularized sparse representation for automatic target recognition in SAR images. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, 2018. 37–40
- 19 Huang Y L, Pei J F, Yang J Y, et al. Neighborhood geometric center scaling embedding for SAR ATR. *IEEE Trans Aerosp Electron Syst*, 2014, 50: 180–192
- 20 Liu X, Huang Y L, Pei J F, et al. Sample discriminant analysis for SAR ATR. *IEEE Geosci Remote Sens Lett*, 2014, 11: 2120–2124
- 21 Dong G G, Kuang G Y. Target recognition in SAR images via classification on riemannian manifolds. *IEEE Geosci Remote Sens Lett*, 2015, 12: 199–203
- 22 Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks. In: *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 2012. 1097–1105
- 23 Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015
- 24 He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016. 770–778
- 25 Xu F, Wang H P, Jin Y Q. Deep learning as applied in SAR target recognition and terrain classification. *J Radars*, 2017, 6: 136–148 [徐丰, 王海鹏, 金亚秋. 深度学习在 SAR 目标识别与地物分类中的应用. *雷达学报*, 2017, 6: 136–148]
- 26 Keydel E R, Lee S W, Moore J T. MSTAR extended operating conditions: a tutorial. In: *Proceedings of SPIE 2757, Algorithms for Synthetic Aperture Radar Imagery III*, 1996. 228–242
- 27 Huang L Q, Liu B, Li B Y, et al. OpenSARShip: a dataset dedicated to Sentinel-1 ship interpretation. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2018, 11: 195–208
- 28 Ding J, Chen B, Liu H W, et al. Convolutional neural network with data augmentation for SAR target recognition. *IEEE Geosci Remote Sens Lett*, 2016, 13: 364–368
- 29 Wagner S A. SAR ATR by a combination of convolutional neural network and support vector machines. *IEEE Trans Aerosp Electron Syst*, 2016, 52: 2861–2872
- 30 Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. In: *Proceedings of the 27th International*

- Conference on Neural Information Processing Systems, 2014. 2672–2680
- 31 Guo J Y, Lei B, Ding C B, et al. Synthetic aperture radar image synthesis by using generative adversarial nets. *IEEE Geosci Remote Sens Lett*, 2017, 14: 1111–1115
 - 32 Bao X J, Pan Z X, Liu L, et al. SAR image simulation by generative adversarial networks. In: *Proceedings of IGARSS*, 2019. 9995–9998
 - 33 Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. 2015. ArXiv:1511.06434
 - 34 Arjovsky M, Chintala S, Bottou L. Wasserstein GAN. 2017. ArXiv:1701.07875
 - 35 Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of Wasserstein GANs. 2017. ArXiv:1704.00028
 - 36 Cui Z Y, Zhang M R, Cao Z J, et al. Image data augmentation for SAR sensor via generative adversarial nets. *IEEE Access*, 2019, 7: 42255–42268
 - 37 Auer S J. 3D synthetic aperture radar simulation for interpreting complex urban reflection scenarios. Dissertation for Ph.D. Degree. Munich: Technical University of Munich, 2011
 - 38 Niu S R, Qiu X L, Peng L X, et al. Parameter prediction method of SAR target simulation based on convolutional neural networks. In: *Proceedings of the 12th European Conference on Synthetic Aperture Radar*, 2018. 106–110
 - 39 Liu L, Pan Z X, Qiu X L, et al. SAR target classification with CycleGAN transferred simulated samples. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, 2018. 4411–4414
 - 40 Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks. In: *Proceedings of IEEE International Conference on Computer Vision (ICCV)*, 2017. 2242–2251
 - 41 Sun Z J, Xue L, Xu Y M. Recognition of SAR target based on multilayer auto-encoder and SNN. *Int J Innov Comput Inf Control*, 2013, 9: 4331–4341
 - 42 Li X, Li C S, Wang P B, et al. SAR ATR based on dividing CNN into CAE and SNN. In: *Proceedings of the 5th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR)*, 2015. 676–679
 - 43 Geng J, Fan J C, Wang H Y, et al. High-resolution SAR image classification via deep convolutional autoencoders. *IEEE Geosci Remote Sens Lett*, 2015, 12: 2351–2355
 - 44 Bentes C, Velotto D, Lehner S. Target classification in oceanographic SAR images with deep neural networks: architecture and initial results. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015. 3703–3706
 - 45 Chen S Z, Wang H P, Xu F, et al. Target classification using the deep convolutional networks for SAR images. *IEEE Trans Geosci Remote Sens*, 2016, 54: 4806–4817
 - 46 Lin Z, Ji K F, Kang M, et al. Deep convolutional highway unit network for SAR target classification with limited labeled training data. *IEEE Geosci Remote Sens Lett*, 2017, 14: 1091–1095
 - 47 Shang R G, Wang J M, Jiao L C, et al. SAR targets classification based on deep memory convolution neural networks and transfer parameters. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2018, 11: 2834–2846
 - 48 Song Q, Xu F. Zero-shot learning of SAR target feature space with deep generative neural networks. *IEEE Geosci Remote Sens Lett*, 2017, 14: 2245–2249
 - 49 Xu B, Chen B, Liu H W, et al. Attention-based recurrent neural network model for radar high-resolution range profile target recognition. *J Electron Inform Technol*, 2016, 38: 2988–2995 [徐彬, 陈渤, 刘宏伟, 等. 基于注意循环神经网络模型的雷达高分辨率距离像目标识别. *电子与信息学报*, 2016, 38: 2988–2995]
 - 50 Pan M, Jiang J, Kong Q P, et al. Radar HRRP target recognition based on t-SNE segmentation and discriminant deep belief network. *IEEE Geosci Remote Sens Lett*, 2017, 14: 1609–1613
 - 51 Pei J F, Huang Y L, Sun Z C, et al. Multiview synthetic aperture radar automatic target recognition optimization: modeling and implementation. *IEEE Trans Geosci Remote Sens*, 2018, 56: 6425–6439
 - 52 He Z Q, Xiao H T, Tian Z Z. Multi-view tensor sparse representation model for SAR target recognition. *IEEE Access*, 2019, 7: 48256–48265
 - 53 Zhang F, Hu C, Yin Q, et al. Multi-aspect-aware bidirectional LSTM networks for synthetic aperture radar target recognition. *IEEE Access*, 2017, 5: 26880–26891
 - 54 Zhou Y, Wang H P, Xu F, et al. Polarimetric SAR image classification using deep convolutional neural networks. *IEEE Geosci Remote Sens Lett*, 2016, 13: 1935–1939
 - 55 Zhang Z M, Wang H P, Xu F, et al. Complex-valued convolutional neural network and its application in polarimetric

- SAR image classification. *IEEE Trans Geosci Remote Sens*, 2017, 55: 7177–7188
- 56 Shang R H, Wang G G, Okoth M A, et al. Complex-valued convolutional autoencoder and spatial pixel-squares refinement for polarimetric SAR image classification. *Remote Sens*, 2019, 11: 522
- 57 Chen H Y, Zhang F, Tang B, et al. Slim and efficient neural network design for resource-constrained SAR target recognition. *Remote Sens*, 2018, 10: 1618
- 58 Shao J Q, Qu C W, Li J W, et al. A lightweight convolutional neural network based on visual attention for SAR image target classification. *Sensors*, 2018, 18: 3039
- 59 Min R, Lan H, Cao Z J, et al. A gradually distilled CNN for SAR target recognition. *IEEE Access*, 2019, 7: 42190–42200
- 60 Hinton G, Vinyals O, Dean J. Distilling the knowledge in a neural network. 2015. ArXiv:1503.02531
- 61 Kang C Y, He C. SAR image classification based on the multi-layer network and transfer learning of mid-level representations. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016. 1146–1149
- 62 Marmanis D, Yao W, Adam F, et al. Artificial generation of big data for improving image classification: a generative adversarial network approach on SAR data. 2017. ArXiv:1711.02010
- 63 Huang Z L, Pan Z X, Lei B. Transfer learning with deep convolutional neural network for SAR target classification with limited labeled data. *Remote Sens*, 2017, 9: 907
- 64 Malmgren-Hansen D, Kusk A, Dall J, et al. Improving SAR automatic target recognition models with transfer learning from simulated data. *IEEE Geosci Remote Sens Lett*, 2017, 14: 1484–1488
- 65 Huang Z L, Pan Z X, Lei B. What, where and how to transfer in SAR target recognition based on deep CNNs. *IEEE Trans Geosci Remote Sens*, 2019. doi: 10.1109/TGRS.2019.2947634
- 66 Borgwardt K M, Gretton A, Rasch M J, et al. Integrating structured biological data by kernel maximum mean discrepancy. *Bioinformatics*, 2006, 22: 49–57
- 67 Pan Z X, Bao X J, Wang B W, et al. Siamese network based metric learning for SAR target classification. In: *Proceedings of IGARSS*, 2019. 1342–1345
- 68 Bucher M, Herbin S, Jurie F. Hard negative mining for metric learning based zero-shot classification. In: *Proceedings of European Conference on Computer Vision*, 2016. 524–531
- 69 Chen G W, Liu L, Hu W L, et al. Semi-supervised object detection in remote sensing images using generative adversarial networks. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, 2018. 2503–2506
- 70 Salimans T, Goodfellow I, Zaremba W, et al. Improved techniques for training GANs. In: *Proceedings of NIPS*, 2016. 2234–2242
- 71 Zhou D Y, Bousquet O, Lal T N, et al. Learning with local and global consistency. In: *Proceedings of NIPS*, 2004. 284–291
- 72 Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules. In: *Proceedings of NIPS*, 2017
- 73 Thys S, van Ranst W, Goedemé T. Fooling automated surveillance cameras: adversarial patches to attack person detection. 2019. ArXiv:1904.08653

Progress of deep learning-based target recognition in radar images

Zongxu PAN^{1,2,3*}, Quanzhi AN^{1,2,3} & Bingchen ZHANG^{1,2,3}

1. *Institute of Electronics, Chinese Academy of Sciences, Beijing 100190, China;*

2. *Key Laboratory of Technology in Geo-spatial Information Processing and Application System, Chinese Academy of Sciences, Beijing 100190, China;*

3. *University of Chinese Academy of Sciences, Beijing 101408, China*

* Corresponding author. E-mail: zxpan@mail.ie.ac.cn

Abstract Radar detection is an effective earth observation means, and target recognition in radar images is its important research direction. Deep learning has been successfully applied to many fields but training deep neural networks requires a mass of data. The lack of samples has become the major factor that impedes the application of deep learning approaches to target recognition in radar images. This paper reviews the research progress of deep learning based target recognition in radar images, with representative methods being combed and summarized. First, data augmentation and neural network models designed for the task of radar image target recognition are introduced. The paper then presents in detail the target recognition methods based on transfer learning, metric learning, and semi-supervised learning in radar images with few samples, which are proposed by our research group. Finally, existing problems and future development trends are discussed.

Keywords radar image, target recognition, deep learning, convolutional neural network, few samples

Zongxu PAN was born in 1986. He received his Ph.D. degree from Tsinghua University, Beijing, China, in 2015. He is currently an associate professor at the Institute of Electronics, Chinese Academy of Sciences, Beijing, China. His research interests include target detection and recognition in optical remote sensing and synthetic aperture radar images, and super-resolution reconstruction of remote sensing images.

Quanzhi AN was born in 1993. He received his B.E. degree from Beijing Institute of Technology, Beijing, China, in 2016. He is currently pursuing his Ph.D. degree at the Institute of Electronics, Chinese Academy of Sciences, Beijing, China. His research interests include target detection and recognition in remote sensing images.

Bingchen ZHANG was born in 1973. He received his Ph.D. degree from the Institute of Electronics, Chinese Academy of Sciences, Beijing, China, in 2017. He is currently a professor at the Institute of Electronics, Chinese Academy of Sciences, Beijing, China. His research interests include sparse microwave imaging, synthetic aperture radars, radar signal processing, and radar systems.