

小样本条件下雷达目标分类识别算法研究

杨石霖

江南机电设计研究所 贵州 贵阳 550009

【摘要】：对于雷达目标识别中非合作目标样本获取难、标注成本高造成的小样本场景，传统识别算法泛化性差、分类精度低等问题，本文对小样本条件下雷达目标分类识别算法进行研究。首先对小样本雷达目标识别的主要难点进行分析，整理出相关的理论基础；然后设计基于多特征融合和元学习的改进识别算法，用特征提取、注意力融合和原型优化来提高小样本场景下特征区分度和模型泛化能力；最后用实验验证算法的有效性，比较传统算法和主流小样本算法的性能差异。

【关键词】：小样本学习；雷达目标分类；特征融合；元学习

DOI:10.12417/3041-0630.26.05.046

1 引言

目前小样本雷达目标识别还存在着不足，一些算法只用一种特征来刻画目标的本质属性，不能很好地表现目标的本质特征，特征融合的方式没有针对性地利用了各个特征之间的互补性，元学习模型任务适配性差，在雷达回波信号复杂的环境下性能不稳定。因此本文提出了一种改进的小样本雷达目标分类识别算法来解决以上问题，提高小样本场景下识别的精度和稳定性，给工程应用提供技术支持。

2 小样本学习核心原理

小样本学习就是用很少的标注样本（一般每类样本不超过20个）来快速训练出具有较好泛化能力的分类模型，其主要思想就是用先验知识迁移和元学习范式来提高模型对于新目标的适应性。常用的有元学习、迁移学习和特征增强这三种小样本学习方法。元学习依靠创建许多类似的小样本任务，使模型学会任务间的共性知识，从而产生元参数，在新的任务上迅速调整，达成高效分类。

3 小样本雷达目标分类识别算法设计

3.1 算法整体框架

本文所设计的小样本雷达目标分类识别算法，由特征提取、特征融合、元学习分类这三个模块组成。首先对雷达回波信号做预处理，得到高分辨距离像、时频特征和自然谐振频率三种主要特征；然后用注意力机制把多种特征融合起来，突出有效特征的权重，抑制冗余信息；最后利用元学习原型网络来优化特征空间的原型表示，从而达到小样本目标分类的目的。

3.2 多特征提取模块

特征提取的主要目的就是抓住目标本质属性，克服雷达回波信号幅度、平移、方位的敏感性。先对雷达回波信号做去噪、归一化预处理，去掉环境干扰和信号畸变的影响。

高分辨距离像特征提取，对预处理过的回波信号做脉冲压

缩得到高分辨距离像，提取波峰数量、质心、最大峰间距等特征，用小波去噪去除目标姿态对距离像的影响，提高特征的稳定性。

时频特征提取，用短时傅里叶变换把回波信号变成时频图像，用卷积神经网络提取时频图像的深层特征，抓住信号的时变特性，表现目标的运动状况和结构信息。

自然谐振频率特征提取，用矩阵束法提取回波信号的自然谐振频率，计算各个频率的模式能量，选出有较强区分度的谐振频率特征，用循环神经网络提取特征序列的时序信息，提高特征的稳健性。

3.3 注意力机制特征融合

为了充分发挥三种特征的互补性来提高特征区分度，设计出一个注意力机制融合模块。将三类特征维度统一之后，输入注意力网络，得到各类特征的权重系数，权重系数根据特征的模式能量和分类贡献度来确定，对于贡献度高的特征给予较大的权重，以抑制冗余特征的影响。

3.4 元学习分类模块

用原型网络作为元学习的基础模型，原型网络用样本特征和各类别原型的距离来完成目标分类。元训练阶段构建大量小样本任务，每个任务包含支持集与查询集，先通过支持集样本生成各类别标准原型 C_k ，原型生成公式如式(1)所示，即对支持集内同类融合特征取均值，得到最具代表性的类别中心。

$$C_k = \frac{1}{K} \sum_{i=1}^N F_{\text{fusion}}^{(k,i)}, k = 1, 2, \dots, C$$

式中： C 为目标类别数， K 为单类别支持集样本数， $F_{\text{fusion}}^{(k,i)}$ 为第 k 类第 i 个样本的融合特征。

元测试阶段，计算查询集样本融合特征与各类别原型的欧氏距离 $d(\cdot, \cdot)$ ，按照距离最小原则完成分类，距离计算公式如式(9)所示。

$$d(F_{\text{fusion}}^q, C_k) = \sqrt{\sum_{j=1}^D (F_{\text{fusion}}^q(j) - C_k(j))^2}$$

式中：D 为融合特征维度， F_{fusion}^q 为查询集样本特征。

为提升模型泛化能力，本文设计加权复合损失函数，融合三元组损失 L_{tri} 、动态时间规整损失 $\{dtw$ 与交叉熵损失 L_{ce} ，权重系数依次设为 2、3、5，总损失函数如式所示，平衡特征判别性与分类精度，避免小样本训练过拟合。

$$L_{\text{total}} = 2L_{\text{tri}} + 3L_{\text{dtw}} + 5L_{\text{ce}}$$

4 实验验证与分析

4.1 实验设置

实验使用 RadChar 雷达数据集和实测高分辨距离像数据集，数据集中有 5 种典型的雷达目标，包括飞机、导弹、舰船等常见的目标，信噪比在 -20dB 到 20dB 之间，每个类别分成支持集和查询集，设置了 1-shot、5-shot、10-shot 三种小样本场景，支持集样本数对应 1、5、10 个，查询集样本数为每个类别 50 个。

实验环境：CPU 为 Intel Core i7-12700H，GPU 为 NVIDIA RTX 3060，内存 16GB，操作系统为 Windows 10，编程语言为 Python，深度学习框架为 PyTorch。

对比算法选择传统的支持向量机、Siamese 网络、传统的原型网络作为对比算法，在相同的实验条件下和本文的算法进行性能比较，评价指标为分类准确率、召回率和运行时间。

4.2 实验结果分析

不同小样本场景下分类准确率对比可知，本文算法在 1-shot 场景下准确率为 78.6%，比支持向量机提高 18.7%，比 Siamese 网络提高 10.2%，比传统原型网络提高 8.5%；5-shot 场景下准确率为 89.3%，比对比算法提高 12.3%~15.6%；10-shot 场景下准确率为 93.5%，具有较好的小样本识别能力。

参考文献：

- [1] 田浩琨.小样本条件下的目标分类与识别算法研究[D].电子科技大学,2022.
- [2] 刘子衿.基于 RBM 分类网络的小样本条件下雷达 HRRP 目标识别技术研究[D].国防科技大学,2020.
- [3] 姜智杰,宋恒,胡楠,等.隧道环境毫米波雷达目标识别与分类算法[J].系统工程与电子技术,2025,47(05):1453-1460.

表 1 实验结果对比

| 算法类型 | 1-shot 准确率 (%) | 5-shot 准确率 (%) | 10-shot 准确率 (%) |
|------------|----------------|----------------|-----------------|
| 传统 SVM | 59.9 | 73.7 | 80.2 |
| Siamese 网络 | 68.4 | 74.7 | 84.3 |
| 传统原型网络 | 70.1 | 76.7 | 86.1 |
| 本文算法 | 78.6 | 89.3 | 93.5 |

召回率对比结果表明，本文算法对于各类目标的召回率都比其他算法要高，在低信噪比下召回率仍能达到 80%以上，说明该算法对噪声干扰有较强的抗干扰能力，可以很好地区分相似的目标。

运行时间分析表明本文算法平均运行时间为 0.82s，比支持向量机和传统的原型网络要稍长一些，但是比 Siamese 网络要短得多，可以满足雷达目标识别的实时性要求。从总体上看，本文的算法在小样本条件下具有较好的分类精度、抗干扰能力和实时性，比现有的其他算法好。

4.3 实验结论

实验结果证明，本文所设计的小样本雷达目标分类识别算法是有效的。多特征融合可以全方位地抓住目标的本质属性，注意力机制提高了有效特征的利用效率，元学习原型网络改善了小样本环境下模型泛化的性能，三者相互配合，较好地解决了小样本条件下雷达目标识别精度低、泛化能力差的问题。

5 结论与展望

本文针对小样本环境下雷达目标分类识别问题，分析了小样本识别的主要困难以及传统算法存在的不足，提出了采用多特征融合和元学习相结合的改进识别算法，用实验结果证明了该算法的有效性。经过研究发现，在少量标注样本的情况下，所提出的方法可以对雷达目标进行准确分类，抗噪声能力强，可以满足实际工程的应用要求。本文的研究还存在小样本环境、复杂的电磁干扰情况下算法性能不佳的问题。未来的研究方向主要是从两个方面入手，第一就是优化特征融合的方式，用自监督学习来提高特征提取的自动化程度，第二就是改进元学习模型的任务适应性，扩大算法在多目标、变姿态场景下的应用范围，提高算法的工程实用性。