

基于多球体空间拓扑约束的雷达目标 HRRP少样本开集识别方法

徐寒铮, 刘 峥*, 许述文, 郭泽坤

(西安电子科技大学雷达信号处理国家重点实验室, 陕西西安 710071)

摘要: 雷达目标高分辨距离像(High Resolution Range Profile, HRRP)因其能够有效表征目标的几何结构与电磁散射特性,在雷达目标识别领域具有重要的应用价值。近年来,深度学习方法凭借其强大的特征表征能力被广泛应用于HRRP目标识别任务。然而,现有基于深度学习的HRRP目标识别方法在少样本开集识别(Few-Shot Open-Set Recognition, FSOSR)场景中,其性能因训练样本少且本身不具备对未知类别的判别能力而受限。为此,本文提出一种基于多球体空间拓扑约束的雷达目标HRRP FSOSR方法。首先,在训练策略上引入元学习框架,从类别充足、样本丰富的辅助数据集采样大量相似且互不重复的任务作为训练单元,学习跨任务共通的知识,使模型在样本稀缺的任务数据集上具备快速泛化能力,缓解少样本模型过拟合问题;其次,在此基础上,设计适用于少样本场景的多球体决策边界建模机制,以超球体分别建模各已知类特征子空间,形成由多球体组成的已知类空间分布,从而隐式建模未知类分布;再次,在多球体之间引入自适应间隔,维持已知类间特定空间拓扑关系,提升决策边界的精细度和鲁棒性;最后,提出难样本学习策略,先经难样本挖掘筛选高价值样本,再借助样本对加权机制定量刻画样本难分程度,使模型依据权重进行针对性学习,从而利用高价值难样本挖掘更精细的差异化特征,以增强模型对细粒度未知类判别能力。实验结果表明:该方法在5-shot及10-shot场景下,相较于现有方法,准确率分别提升6.17个百分点和2.94个百分点,AUROC指标分别提升13.1个百分点和12.94个百分点,验证了该方法的有效性与稳健性。此外,通过在瑞芯微RK3588嵌入式人工智能(Artificial Intelligence, AI)芯片上完成模型部署,所提方法推理时延2.197 ms,功耗为2.25 W,充分验证了该方法的工程可实现性。该方法适用于未知类频发的复杂场景,可支撑高分辨体制雷达对非合作目标的探测识别;同时,得益于良好的工程可实现性,该方法亦适用于机载平台等高实时性需求、硬件资源受限的应用场景。

关键词: 雷达目标识别;高分辨距离像(HRRP);深度学习;元学习;少样本开集识别(FSOSR)

基金项目: 国家自然科学基金(No.62371382, No.U24A20217)

中图分类号: TN959.1+7

文献标识码: A

文章编号: 0372-2112(2026)03-1209-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250705

A Few-Shot Open-Set Recognition Method for Radar Target HRRP Based on Multi-Hypersphere Spatial Topological Constraints

XU Hanzheng, LIU Zheng*, XU Shuwen, GUO Zekun

(National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: Radar target high-resolution range profile (HRRP) has significant application value in radar target recognition due to its ability to effectively characterize the geometric structure and electromagnetic scattering properties of targets. In recent years, deep learning methods have been widely applied to HRRP-based target recognition tasks owing to their powerful feature representation capability. However, existing deep learning-based radar target recognition methods using HRRP suffer from performance degradation in few-shot open-set recognition (FSOSR) scenarios due to limited training samples and inherent inability to discriminate unknown classes. To address this issue, this paper proposes a radar target HRRP few-shot open-set recognition method based on multi-hypersphere spatial topological constraints. First, a meta-learning framework is introduced in the training strategy. A large number of similar yet non-overlapping tasks are sampled from an auxiliary dataset with sufficient categories and abundant samples as training units to learn cross-task common knowledge, enabling the model to generalize rapidly on sample-scarce task datasets and alleviating few-shot overfitting. On this basis, a multi-hypersphere decision boundary modeling mechanism suitable for few-shot scenarios is designed. Each known class feature subspace is modeled by an individual hypersphere, forming a multi-hypersphere representation of the known-class feature space, which implicitly models the distribution of unknown classes. Meanwhile, adaptive margins are intro-

duced between hyperspheres to maintain specific spatial topological relationships among known classes, thereby improving the refinement and robustness of the decision boundaries. Furthermore, a hard sample learning strategy is proposed. High-value samples are first selected through hard sample mining, after which a sample-wise weighting mechanism is employed to quantitatively characterize the hardness of samples. The model then performs targeted learning according to the assigned weights, enabling the extraction of finer discriminative features from informative hard samples and enhancing the model's capability to distinguish fine-grained unknown classes. Experimental results demonstrate that, in the 5-shot and 10-shot scenarios, the proposed method achieves accuracy improvements of 6.17 percentage point and 2.94 percentage point, and AU-ROC improvements of 13.1 percentage point and 12.94 percentage point compared with the state-of-the-art methods, respectively, verifying the effectiveness and robustness of the proposed approach. In addition, the model is deployed on the Rockchip RK3588 embedded artificial intelligence (AI) chip, achieving an inference latency of 2.197 ms and a power consumption of 2.25 W, which demonstrates its engineering feasibility. The proposed method is suitable for complex environments where unknown classes frequently appear, and can support high-resolution radar systems in the detection and recognition of non-cooperative targets. Moreover, due to its favorable engineering feasibility, the method is also applicable to scenarios with stringent real-time requirements and limited hardware resources, such as airborne platforms.

Keywords: radar target recognition; high resolution range profile (HRRP); deep learning; meta-learning; few-shot open-set recognition (FSOSR)

Foundation Item(s): National Natural Science Foundation of China (No.62371382, No.U24A20217)

0 引言

雷达目标高分辨距离像 (High Resolution Range Profile, HRRP) 是由高分辨雷达获取的目标散射中心子回波沿雷达视线投影的向量和, 其包含了目标散射中心的分布信息、目标结构以及尺寸等重要特征^[1-3]。相较于合成孔径雷达 (Synthetic Aperture Radar, SAR), HRRP 具有易获取、易处理和易存储等特点^[4], 因此成为雷达自动目标识别 (Radar Automatic Target Recognition, RATR) 的重要数据来源, 相关研究备受关注^[5]。

传统基于 HRRP 的雷达目标识别方法主要通过提取人工设计的几何结构、统计、时频变换等特征, 并结合浅层机器学习分类器实现目标分类^[6-9]。但此类方法存在一定的局限性, 即人工特征设计高度依赖专家经验, 且浅层模型的特征表征能力有限。近年来, 随着深度学习理论的迅速发展, 深度神经网络 (Deep Neural Network, DNN) 凭借其强大的深层特征表征能力在雷达 HRRP 目标识别领域受到广泛关注, 有效提升了识别精度^[10-12]。然而, 此类方法通常依赖于大规模训练样本, 在实际常遇的少样本场景下识别性能受限。

为解决训练样本受限问题, 诸多雷达目标 HRRP 少样本识别 (Few-Shot Recognition, FSR) 方法相继被提出^[13-16]。主要包括迁移学习类^[13]、数据生成类^[14-15]和元学习类^[16]方法。然而, 现有 HRRP FSR 方法均基于闭集识别 (closed-Set recognition) 假设, 即测试样本均来自训练类别, 缺乏未知类判别能力。因此, 面向更贴合实际的开集识别 (Open-set Recognition, OSR) 应用场景, 雷达目标 HRRP OSR 问题逐渐成为研究焦点。

现有 HRRP OSR 方法^[17-19]主要通过构建未知类决策边界实现未知类判别, 但普遍依赖于大量已知类样本构造未知类决策边界, 在少样本场景下难以适用。

为破解少样本场景下未知类拒判难题, 少样本开集识别 (Few-Shot Open-Set Recognition, FSOSR)^[20-23]应运而生。FSR、OSR 与 FSOSR 概念差异如图 1 所示。FSR 通过少量样本生成类原型并建立已知类决策边界, 缺乏未知类判别能力, 如图 1(a) 所示; OSR 通过决策边界区分已知类与未知类, 但需依赖大量已知类样本构建边界, 如图 1(b) 所示; FSOSR 旨在通过少量样本构建同时具备已知类分类与未知类判别能力的模型, 如图 1(c) 所示。

现有 FSOSR 方法多采用元学习框架, 并在此基础上设计开集分类器。文献[20-22]在元学习框架基础上, 通过样本生成^[21]或选取无关数据集样本^[20, 22]作为伪未知类, 学习未知类决策边界。然而, 此类方法性能高度取决于伪样本与真实未知类的分布相似度, 在实际场景中难以保证适配性。针对这一缺陷, 文献[23]提出不依赖伪未知样本的 FSOSR 方法, 基于变化一致性理论设计变换函数, 通过样本变换前后的差异检测未知类, 但该方法性能依赖变换函数设计, 通用性受限。更关键的是, 上述 FSOSR 成果均聚焦于计算机视觉领域, 而光学图像与雷达 HRRP 数据存在本质差异, 直接降低了此类方法在 HRRP 识别中的适用性。

综上所述, 现有方法难以适配样本稀缺、未知类目标突发的实际雷达目标识别场景。为此, 本文提出一种基于多球体空间拓扑约束的雷达目标 HRRP FSOSR 方法。总体思路为: 首先, 引入元学习框架提




图1 FSR、OSR以及FSOSR概念对比

Figure 1 Comparison of the concepts of few-shot recognition, open-set recognition, and few-shot open-set recognition

升少样本泛化能力,设计无需伪未知样本、适用于少样本场景的多球体决策边界建模机制,用于隐式划分未知类决策域;其次,引入自适应间隔维持球体空间拓扑关系,细化决策边界,设计难分样本学习策略增强细粒度未知类鉴别能力。最后,通过计算机仿真实验和模型的嵌入式部署,验证方法的性能和工程可实现性。

1 FSOSR任务定义

本文方法在训练策略上引入元学习框架,以“任务”为基本单元,从类别充足、样本丰富的辅助数据集中采样任务以学习跨任务先验知识,实现少样本场景下的快速泛化。“任务”被形式化为 N -way K -shot 分类任务,记为 $T = \{S, Q\}$, 支持集 $S = \{x_i, y_i\} (i = 1, 2, \dots, N \times K)$, 含 N 个类别、每类 K 个训练样本, K 往往较小(如 $K = 5$); 查询集 $Q = \{x_i, y_i\} (i = N \times K + 1, N \times K + 2, \dots, N \times K + M)$, 含 M 个测试样本; 其中, x_i 为 HRRP 样本, y_i 为样本标签。在 FSOSR 任务中, 查询集 Q 包含已知类样本 Q^{Seen} 和未知类样本 Q^{Unseen} , 即 $Q = Q^{\text{Seen}} \cup Q^{\text{Unseen}}$; Q^{Seen} 与 S 类别相同, Q^{Unseen} 与 S 类别不同。最终, 模型需具备对 Q^{Seen} 的分类能力以及对 Q^{Unseen} 的鉴别能力。

2 基于多球体空间拓扑约束的雷达目标 HRRP FSOSR 方法

本文方法原理示意图如图 2 所示, 包括特征空间映射、多球体建模、自适应间隔与空间拓扑约束、难分样本学习四个步骤。特征空间映射采用如图 3 所示的一维残差 ResNet-12 网络作为特征提取器, 自动提取 HRRP 的深层特征向量。在后续小节中, 分别对多球体建模、自适应间隔与空间拓扑约束、难分样本学习策略以及综合三种策略所得的损失函数进行介绍, 最后给出模型训练与测试流程。

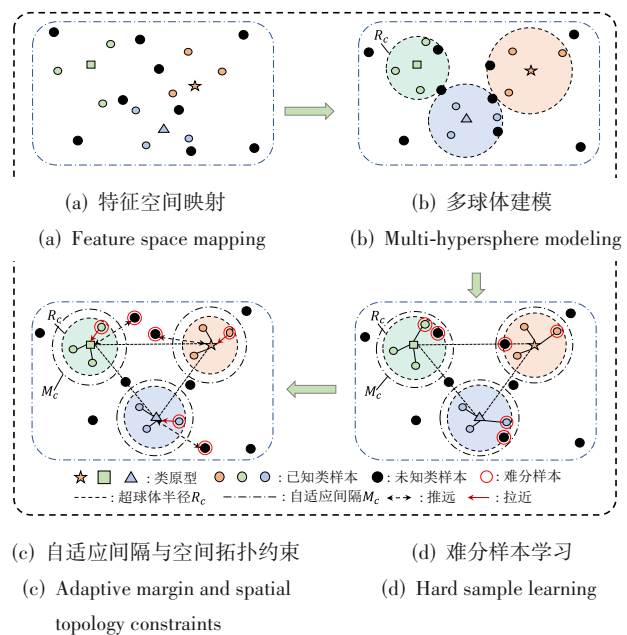


图2 本文方法的关键步骤与原理示意图

Figure 2 Illustration of the key steps and principles of the proposed method




图3 一维残差 ResNet-12 网络架构

Figure 3 Architecture of the 1D ResNet-12 network

2.1 多球体建模

少样本场景下已知类目标在特征空间的分布难以被准确估计, 而超球体可通过少量样本为已知类目标快速建立决策边界, 是适用于少样本场景的决策边界建模方式, 但单超球体建模精细化程度不足。据

此,本文提出一种多球体决策边界建模机制:以超球体分别建模各已知类子空间,形成由多球体组成的已知类空间分布,从而隐式刻画未知类分布,如图2(b)所示。其流程为:先由各类支持集样本生成类原型,再以类原型为球心构造超球体。

2.1.1 类原型生成

采用一维残差 ResNet-12 网络作为特征提取器 $f_\theta(\cdot): \mathbb{R}^d \rightarrow \mathbb{R}^h$ (θ 为其参数, h 为特征向量维度), 对 HRRP 样本 $\mathbf{x}_i \in \mathbb{R}^d$ 提取特征 $f_\theta(\mathbf{x}_i)$, 再对各类支持集样本特征取均值的初始类原型:

$$\mathbf{p}_c = \frac{1}{|S_c|} \sum_{\mathbf{x}_i \in S_c} f_\theta(\mathbf{x}_i) \quad (1)$$

$$\mathbf{P} = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N\} \quad (2)$$

其中, \mathbf{p}_c 为类别 c 的原型; S_c 为类别 c 的支持集样本; \mathbf{P} 为类初始类原型集。均值类原型易受噪声或异常样本干扰而偏离真实类中心, 故借鉴文献[24]的任务自适应增强方法, 采用 DeepSets^[25] 集合变换函数增强类原型:

$$\mathbf{p}'_c = \mathbf{p}_c + g\left(\left[\mathbf{p}_c; \max_{\mathbf{p}_{c'} \in \mathbf{P}_{c'}} h(\mathbf{p}_{c'})\right]\right) \quad (3)$$

$$\mathbf{P}' = \{\mathbf{p}'_1, \mathbf{p}'_2, \dots, \mathbf{p}'_N\} \quad (4)$$

其中, $g(\cdot)$ 和 $h(\cdot)$ 为非线性 MLP 层; $[\cdot; \cdot]$ 通道拼接操作; $\mathbf{P}_{c'} = \mathbf{P} - \{\mathbf{p}_{c'}\}$ 为 $\mathbf{p}_{c'}$ 的补集。最终得到增强后的类原型集 \mathbf{P}' 。

2.1.2 超球体构建

类原型表征类别中心, 因此可将各类别原型作为球心分别构造超球体。对于类别 c , 将支持集划分为正样本集 $\mathbf{X}_c^+ = \{\mathbf{x}_i^+, \mathbf{y}_i^+\} (i=1, 2, \dots, K)$ 和负样本集 $\mathbf{X}_c^- = \{\mathbf{x}_i^-, \mathbf{y}_i^-\} (i=1, 2, \dots, (N-1)K)$, 其中 $\mathbf{y}_i^+ = c, \mathbf{y}_i^- \neq c$, 依据类原型 \mathbf{p}'_c 以及相应的正、负样本集, 定义正样本对 $\{d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+))\}, i=1, 2, \dots, K$ 以及负样本对 $\{d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-))\}, i=1, 2, \dots, (N-1)K, \mathbf{x}_i^+, \mathbf{x}_i^- \in S$, 则超球体半径 R_c 可依据正样本对距离的集合确定, 计算式为

$$R_c = h_{v_1}\left(\left\{d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+))\right\}, i=1, 2, \dots, K\right) \quad (5)$$

其中, $h(\cdot)$ 为分位函数; v_1 为超参数, 代表对超出超球体区域正样本的容忍度; $d(\cdot)$ 为欧式距离。在模型训练过程中, 通过优化类原型和半径来更新各类别超球体子空间, 具体将在 3.2 节介绍。因此, 类别 c 的超球体可表示为

$$H_c = \{\mathbf{p}'_c, R_c\} \quad (6)$$

2.2 自适应间隔与空间拓扑约束

多球体建模已知类空间后, 未知类的决策域对应球体之外区域。由于球体间可能发生混叠, 导致落入

超球体间隙的未知类易被误判, 如图 2(b) 所示。为此, 本文依据类内以及类间几何关系, 在超球体间引入自适应间隔并约束球体空间拓扑。对于类别 c , 要求超球体 H_c 与其余球体距离足够远, 引入如式(7)所示的约束。

$$d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)) \geq R_c + M_c, c=1, 2, \dots, N \quad (7)$$

其中, $\mathbf{x}_i^- \in \mathbf{X}_c^-$; M_c 为 H_c 的自适应间隔。 M_c 计算方法为

$$M_c = h_{v_2}\left(\left\{d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)) - R_c\right\}, i=1, 2, \dots, (N-1)K\right) \quad (8)$$

其中, $h(\cdot)$ 为分位函数; v_2 为超参数, 代表对违约负样本的容忍度; $d(\cdot)$ 为欧式距离。 M_c 由类原型、负样本以及超球体半径间的相对位置关系确定, 可动态匹配特征空间尺度, 结合拓扑约束可避免球体混叠, 细化决策边界。

2.3 难分样本学习策略

细粒度未知类目标的特征分布与已知类高度相似, 极易导致模型将其误判为已知类, 如图 2(c) 所示。相较于易分样本, 难分样本蕴含更丰富的判别信息, 有助于模型捕捉不同类别间的细微差异。受文献[26-27]启发, 本文提出一种难分样本学习策略, 通过聚焦高价值难分样本学习精细的差异化特征, 从而提升模型对细粒度未知类样本的鉴别能力, 如图 2(d) 所示。具体包括难分样本挖掘及样本对加权机制, 首先通过难分样本挖掘初步筛选出难分样本, 然后通过样本对加权机制使用权重定量, 以描述样本难分程度。

2.3.1 难分样本挖掘

样本的难分程度由其在特征空间中的分布、建立的决策边界以及分类决策规则决定。为此, 本文基于“球体边界距离+类内-类间距离”筛选出难分样本。

对于类别 c 的正样本 \mathbf{x}_i^+ , 难分样本筛选条件为

$$d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+)) > \min\left\{d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)) - M_c\right\}, i=1, 2, \dots, (N-1)K \quad (9)$$

对于类别 c 的负样本 \mathbf{x}_i^- , 筛选条件为

$$d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)) < \max\left\{d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+)) + M_c\right\}, i=1, 2, \dots, K \quad (10)$$

将最终筛选出的难分正样本集记为 \mathbf{X}'_c^+ ($\mathbf{X}'_c^+ \in \mathbf{X}_c^+$), 难分负样本集记为 \mathbf{X}'_c^- ($\mathbf{X}'_c^- \in \mathbf{X}_c^-$)。

本文所提筛选条件与 2.2 节所述空间拓扑约束以及后续分类决策规则在逻辑上保持一致, 能够有效筛选出高价值难分样本。通过难分样本挖掘, 可规避无学习价值的易分样本干扰导致的低效学习, 从而提升模型的训练效率。

2.3.2 样本对加权机制

难分样本挖掘虽初步筛选出高价值难分样本, 但

不同样本的难分程度存在差异,对模型特征学习的贡献度也各不相同;若为所有难分样本赋予相同权重,则难以充分利用样本差异化价值。为此,本文提出一种样本对加权机制,使用样本对权重定量描述样本难分程度。

样本对距离 $d_{ij} = d(\mathbf{p}'_i, f_\theta(\mathbf{x}_j))$, 其中 $d(\cdot)$ 为距离函数, d_{ij} 表示第 i 类的第 j 个样本对距离, 构建距离矩阵 $\mathbf{D} \in \mathbb{R}^{N \times NK}$, 基于样本对的损失函数为 $L(\mathbf{D})$ 。在第 t 轮迭代中损失函数对模型参数 θ 的梯度为

$$\begin{aligned} \left. \frac{\partial L(\mathbf{D})}{\partial \theta} \right|_t &= \left. \frac{\partial L(\mathbf{D})}{\partial \mathbf{D}} \right|_t \left. \frac{\partial \mathbf{D}}{\partial \theta} \right|_t \\ &= \sum_{i=1}^N \sum_{j=1}^{NK} \left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t \left. \frac{\partial d_{ij}}{\partial \theta} \right|_t \end{aligned} \quad (11)$$

构造等价函数 $F(\mathbf{D})$

$$F(\mathbf{D}) = \sum_{i=1}^N \sum_{j=1}^{NK} \left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t d_{ij} \quad (12)$$

其中, $\left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t$ 项可以视为常数。 $F(\mathbf{D})$ 对 θ 的梯度与式(11)等价。

结合“正样本对聚拢、负样本对远离”的约束,可假设正样本对的 $\left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t \geq 0$, 负样本对的 $\left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t \leq 0$, 则式(12)可展开为样本对加权形式:

$$\begin{aligned} F(\mathbf{D}) &= \left(\sum_{j=1}^K \left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t d_{ij} + \sum_{j=K+1}^{NK} \left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t d_{ij} \right) \\ &= \left(\sum_{j=1}^K w_j^+ d_{ij} - \sum_{j=K+1}^{NK} w_j^- d_{ij} \right) \end{aligned} \quad (13)$$

其中, $w_j^+ = \left| \left. \frac{\partial L(\mathbf{D})}{\partial d_{ij}} \right|_t \right|$, 代表样本对 $\{\mathbf{p}'_i, f_\theta(\mathbf{x}_j)\}$ 的权重。

基于此,本文设计了一种样本对加权机制,进一步对筛选出的难分样本赋予更精确的权重;具体地,对于正样本对 $\{\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+)\}$, $\mathbf{x}_i^+ \in \mathbf{X}_c^+$, 其权重 w_i^{c+} 为

$$w_i^{c+} = \frac{e^{a(d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+)) - R_c)}}{1 + \sum_{\mathbf{x}_i^+ \in \mathbf{X}_c^+} e^{a(d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+)) - R_c)}} \quad (14)$$

对于负样本对 $\{\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)\}$, $\mathbf{x}_i^- \in \mathbf{X}_c^-$, 其权重 w_i^{c-} 为

$$w_i^{c-} = \frac{e^{-\beta(d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)) - (R_c + M_c))}}{1 + \sum_{\mathbf{x}_i^- \in \mathbf{X}_c^-} e^{-\beta(d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)) - (R_c + M_c))}} \quad (15)$$

难分程度愈高的正样本,对应的 $d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+))$ 越

大,赋予的权重 w_i^{c+} 也相对增加,负样本亦同理。类似于注意力机制,样本对加权机制使得模型能够依据样本对难分程度的高低,赋予相应的关注度,进行针对性学习,从而提升模型学习效率。

2.4 多球体空间拓扑约束损失函数

本文提出多球体空间拓扑约束损失函数 $\text{Loss}_{\text{MSTC}}$, 如式(16)所示。该函数将多球体建模、自适应间隔与空间拓扑约束、难分样本学习集成于统一的损失函数框架下,实现端到端优化。

$$\begin{aligned} \text{Loss}_{\text{MSTC}} &= \omega_1 L_{\text{CE}} + (1 - \omega_1) \frac{1}{N} \\ &\cdot \sum_{c=1}^N \left\{ \lambda R_c^2 + \frac{1}{\alpha} \ln \left[1 + \sum_{\mathbf{x}_i^+ \in \mathbf{X}_c^+} e^{a(d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^+)) - R_c)} \right] \right\} \\ &+ (1 - \omega_1) \frac{1}{N} \\ &\cdot \sum_{c=1}^N \left\{ \frac{1}{\beta} \ln \left[1 + \sum_{\mathbf{x}_i^- \in \mathbf{X}_c^-} e^{-\beta(d(\mathbf{p}'_c, f_\theta(\mathbf{x}_i^-)) - (R_c + M_c))} \right] \right\} \end{aligned} \quad (16)$$

其中, λR_c^2 项用于最小化超球体体积, λ 为权衡因子; 最后两项为对比损失项, 约束正样本聚拢于各类超球体子空间之内、负样本远离至决策边界 $R_c + M_c$ 之外, α 及 β 为正、负样本对的尺度因子; ω_1 为损失权衡因子; L_{CE} 为闭集分类损失项, 用于最小化类内方差, 如式(17)所示:

$$L_{\text{CE}} = - \sum_{(\mathbf{x}_i, y_i) \in \mathcal{Q}} \ln p(y_i | \mathbf{x}_i) \quad (17)$$

其中, $p(y = k | \mathbf{x}_i)$ 为样本的概率分布, 计算式为

$$p(y = k | \mathbf{x}_i) = \frac{e^{-d(f_\theta(\mathbf{x}_i), \mathbf{p}'_k)}}{\sum_{i=1}^N e^{-d(f_\theta(\mathbf{x}_i), \mathbf{p}'_i)}} \quad (18)$$

2.5 模型训练与测试

模型训练与测试流程如图4所示, 其中特征提取模块、决策边界生成模块计算流程如图5所示。

在预训练阶段, 基于样本与类别丰富的辅助数据集 D_{base} , 使用全连接分类器预训练特征提取网络, 以提升其泛化性能。在元训练阶段, 从 D_{base} 中采样得到元训练任务, 基于多球体空间拓扑约束损失 $\text{Loss}_{\text{MSTC}}$ 训练模型, 使其学习跨任务先验知识。在元测试阶段, 从任务数据集 D 中采样元测试任务, 利用含少量训练样本的支持集微调模型, 更新决策边界。在测试时, 查询集样本经特征提取得特征向量; 模型依据决策边界输出样本未知类得分 scores , 并依据门限 τ 鉴别未知类; 若判别为已知类, 则依据式(18)计算类别的概率分布, 选取最大值作为类标签。未知类得分计

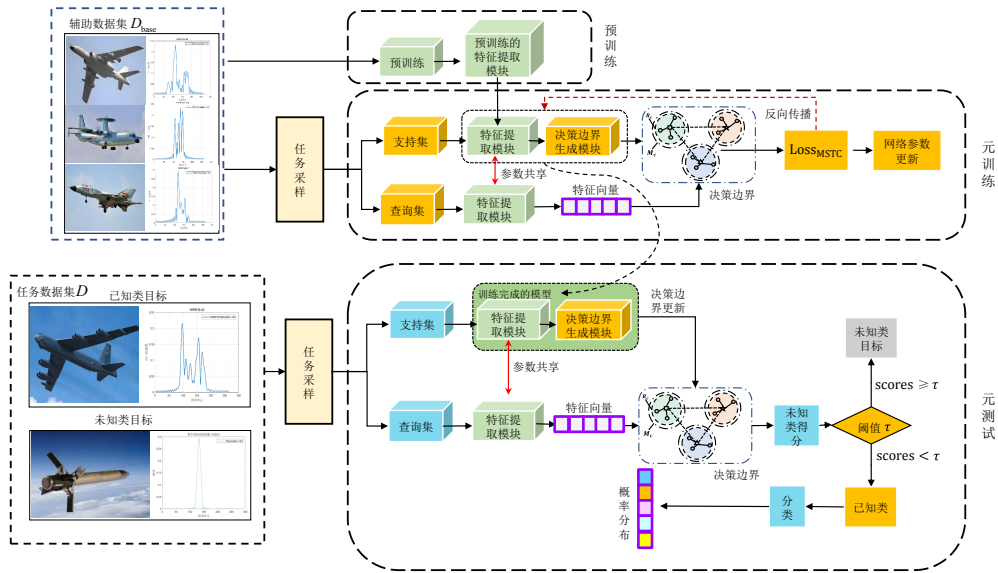


图4 模型训练与测试流程

Figure 4 Training and testing procedures of the model




图5 特征提取模块与决策边界生成模块计算流程

Figure 5 Workflow of the feature extraction module and the decision boundary generation module

算方法为

$$\text{scores} = \min \{d(f_{\theta}(x_i), p'_c) - R_c\}, c = 1, 2, \dots, N \quad (19)$$

未知类判别规则为

$$\begin{cases} \text{scores} \geq \tau, \text{未知类} \\ \text{scores} < \tau, \text{已知类} \end{cases} \quad (20)$$

3 实验结果与分析

3.1 实验数据构建

实验采用空中目标仿真 HRRP 数据。通过 3D 制图软件构建 15 类空中飞行目标模型,经 Feko 电磁仿真软件计算得到宽带电磁散射数据,对该数据做逆傅里叶变换处理得到目标的 HRRP。采用 2 范数归一化和重心对齐法对所得 HRRP 进行预处理,克服 HRRP 幅度和平移敏感性问题。在 15 类目标中 8 类作为辅助数据集 D_{base} , 7 类作为任务数据集 D , 任务数据集为目标在特定飞行姿态下获取的 HRRP 序列。雷达仿真参数设定如表 1 所示。图 6 给出了波音-737 飞机的仿真 HRRP 与实测 HRRP 对比图。数据集划分、目标

具体类型以及姿态角范围如表 2 所示。

表 1 雷达仿真参数设置

Table 1 Radar simulation parameter settings

带宽/MHz	距离分辨率/m	波段	极化方式
50	3	Ku	HH

3.2 实验设定


本文采用一维卷积核的 ResNet-12 网络提取 HRRP 深层特征。先基于辅助数据集预训练 ResNet-12, 再依次进行元训练与元测试。在元训练阶段, 采用 Adam 优化器。鉴于网络参数 θ 、超球体半径 R_c 及间隔 M_c 的尺度差异, 同步更新三者参数不合理。故本文参考文献[28]采用交替最小化坐标下降法优化, 先固定 R_c 和 M_c 并更新 θ , 再基于更新后的 θ 优化 R_c 和 M_c 。FSOSR 场景设定: (1) 元训练阶段 $N=5, K=5, 10$; (2) 元测试阶段 $N=5, K=5, 10$, 查询集中每类 15 个样本, 且已知类别数为 5, 未知类别数为 2。当训练时采样 500 个元训练任务, 测试时采样 1 000 个元测试任务评估性能。模型性能采用准确率 (Accuracy, ACC)、ROC 曲线下区域面积 (Area Under the Receiver Operating Characteristic curve, AUROC) 及真阳率 95% 条件下的假阳率 (False Positive Rate at 95% true positive rate, FPR95) 指标综合评估。ACC 衡量模型的闭集分类性能, AUROC 用于综合衡量模型 OSR 性能, FPR95 衡量模型对未知类的误判概率, 值越小性能越优。

3.3 FSOSR 结果


对比实验选取原型网络-支持向量数据描述 (Prototypical Networks-Support Vector Data Description, PN-

表 2 目标类型信息
Table 2 Target type information

数据集划分	机型	尺寸/m			HRRP 角域范围/(°)
		长	高	翼展	
任务数据集 D	F-16 战斗机	15.09	5.09	9.45	俯仰角 70.9~83.2 方位角 20.1~123.4
	EA-37B 电子战机	29.40	7.90	28.50	
	AN-71 预警机	23.50	9.20	31.89	
	B-52 轰炸机	48.50	12.40	56.40	
	KC-46 加油机	48.50	5.41	47.57	
	BGM-109 巡航导弹	6.25	0.52	2.67	
	AN/ALE-50 拖曳式干扰	2.00	0.30	2.00	
辅助数据集 D_{base}	运-20	47.00	15.00	45.00	俯仰角 85 方位角 0~180
	波音-777	73.90	18.50	60.90	
	麦道 DC-10	55.50	17.70	47.30	
	轰-6K	34.80	10.36	33.00	
	波音-737	39.50	12.60	34.20	
	空警-500	34.02	11.45	40.40	
	A-320	37.57	11.76	34.10	
	歼-8	21.52	9.34	5.41	



(a) 波音-737 仿真 HRRP
(a) Simulated HRRP of the Boeing 737



(b) 波音-737 实测 HRRP
(b) Measured HRRP of the Boeing 737

图 6 波音-737 飞机:仿真与实测 HRRP 对比

Figure 6 Comparison of simulated and measured HRRPs for the Boeing 737 aircraft

SVDD)^[29]、开集元学习 (oPen sEt mEta LEaRning, PEELER)^[20]、SnaTCHer^[23]及全局-局部能量学习 (Global Energy-based Learning, GEL)^[22]四种方法。PN-SVDD 结合 ProtoNet^[29](经典 FSR 方法)与支持向量数据描述 (Support Vector Data Description, SVDD)^[30](传统单分类器)实现分类与未知类鉴别。PEELER、SnaTCHer 和 GEL 为计算机视觉领域三种具有代表性的 FSOSR 方法。为保证对比的公平性,所有方法均采用 ResNet-12 作为特征提取器。

首先,任选 5 类目标作为已知类,其余 2 类作为未知类,结果如表 3 所示,本文方法在少样本开集场景下性能最优。

表 3 FSOSR 性能对比

单位:%

Table 3 Comparison of few-shot open-set recognition performance unit:%

模型	5-way 5-shot			5-way 10-shot		
	ACC	AUROC	FPR95	ACC	AUROC	FPR95
PN-SVDD ^[29]	84.12	59.37	77.20	88.22	59.20	77.52
PEELER ^[20]	82.26	64.22	70.08	86.82	69.94	63.13
SnaTCHer ^[23]	88.85	78.18	47.68	93.67	80.20	46.57
GEL ^[22]	88.18	60.24	66.33	86.54	63.03	61.71
本文方法	95.02	91.28	27.96	96.61	93.14	22.85

(1) 已知类分类性能: 在 5-shot 以及 10-shot 设定下,本文方法 ACC 均优于其他方法,较次优方法分别

提升 6.17 个百分点、2.94 个百分点,说明难分样本学习策略有助于模型学习精细的差异化特征,从而同步提升已知类分类与未知类鉴别能力。

(2)未知类鉴别性能:在 5-shot 及 10-shot 设定下,PN-SVDD 方法因极端少样本条件下 SVDD 过拟合,且 SVDD 单球体建模决策边界精细程度不足,故而性能最差。PEELER 和 GEL 方法依赖伪未知样本策略,性能受限于伪未知样本的质量。SnaTCHer 方法不依赖于伪未知样本,取得了次优的性能,但其性能依赖变化函数的设计。本文方法 AUROC 较次优方

法分别提升 13.1 个百分点、12.94 个百分点,FPR95 分别降低 19.72 个百分点、23.72 个百分点,各项指标均达最优。

为进一步验证所提方法的有效性,图 7 展示了各方法在 5-way 10-shot 设定下的未知类归一化得分的核密度估计分布(统计 600 个元测试任务)。通过相交区域面积(Intersection over Union, IoU)定量刻画已知类与未知类得分的重叠程度,IoU 越小代表模型 OSR 性能越优。由图 7 可知,本文方法的重叠区域最小(IoU 最低),表明其对已知类与未知类的区分能力更优。

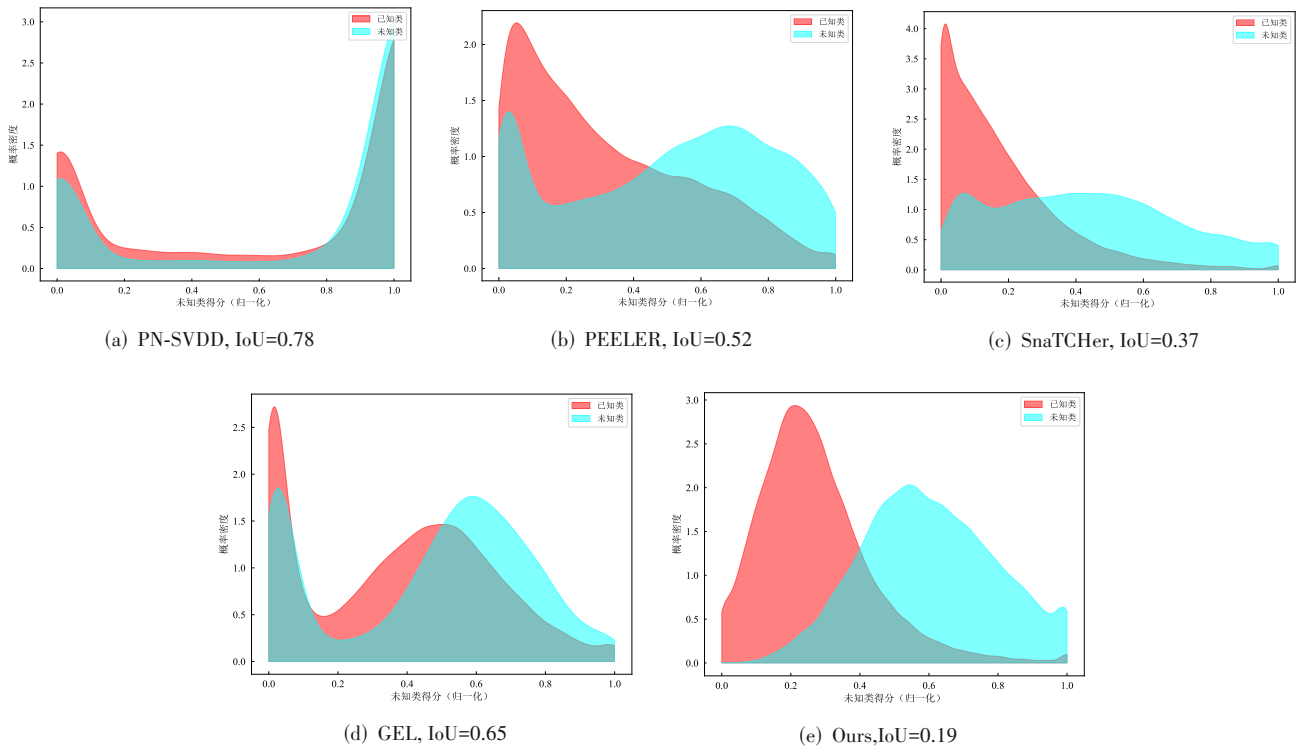


图 7 5-way 10-shot 场景下不同方法未知类得分的分布情况

Figure 7 Distribution of unknown-class scores for different methods in the 5-way 10-shot scenario

为验证本方法对细粒度未知类的鉴别能力,在任务数据集中,选取 AN/ALE-50 拖曳式干扰和 BGM-109 巡航弹作为细粒度未知类,其余 5 类目标作为已知类。由于该数据雷达距离分辨率仅为 3 m,未知类目标 AN/ALE-50、BGM-109 与已知目标中的 F-16 尺寸相对接近,在部分角域下三者的 HRRP 较为相似,因此分辨难度更高,如图 8 所示。该设定下的实验结果如表 4 所示。

可以发现,在细粒度未知类识别场景下,对比方法中 PN-SVDD、PEELER 及 SnaTCHer 方法开集识别(Open-Set Recognition, OSR)性能均出现了较为严重的下降,说明这些方法对细粒度未知类的判别能力不佳。GEL 方法在该场景下取得了较好的性能,但在表 3 中

更具一般性的任务中却表现较差,说明该方法泛化性能较弱。本文所提方法无论在更具一般性的任务还是细粒度未知类识别任务中均取得了最优的表现,验证了其有效性且具备较好的泛化性能。

3.4 消融实验

为验证所提方法中各组件的有效性,并定量刻画这些组件对模型性能的影响,本文开展了消融对比实验。首先,以 ProtoNet^[29]作为基准方法,由于其不具备未知类鉴别能力,参照文献[22],以样本到类原型的最小距离作为其未知类得分,然后构造了本文方法的四种变体,表 5 给出了 5-way 10-shot 细粒度未知类识别场景下的消融实验结果。




图 8 部分角域下 F-16、BGM-109 与 AN/ALE-50 三类目标的 HRRP 对比

Figure 8 Comparison of the HRRPs of the F-16, BGM-109, and AN/ALE-50 targets within a partial aspect range

表 4 细粒度未知类识别性能对比 单位:%

Table 4 Performance comparison for fine-grained unknown-class recognition unit:%

模型	5-way 5-shot			5-way 10-shot		
	ACC	AUROC	FPR95	ACC	AUROC	FPR95
PN-SVDD ^[29]	86.15	54.54	70.39	88.27	55.92	70.09
PEELER ^[20]	88.47	22.69	96.31	89.90	25.64	96.27
SnaTCHer ^[23]	90.34	73.38	37.61	92.31	75.95	33.46
GEL ^[22]	89.94	90.17	12.57	92.55	91.95	10.75
本文方法	91.08	91.15	19.20	94.48	95.63	6.80

注:细粒度未知类包括 AN/ALE 和 BGM-109。

对表 5 结果分析如下。

(1)多球体建模:对比基准方法,设定 1 的 AUROC 提高了 19.67 个百分点,验证了多球体建模在少样本场景下对未知类判别的有效性;但 ACC 相对于基准方法下降了 8.52 个百分点,主要原因在于多球体之间发生混叠导致建模失效。

(2)自适应间隔与空间拓扑约束:在设定 2 中,ACC 和 AUROC 相对于设定 1 分别提升了 8.94 个百分点及 5.66 个百分点,且 ACC 与基准方法相当,验证了自适应间隔与空间拓扑约束策略优化了多球体建模的效果。

(3)难分样本学习:在设定 3 中,模型 ACC 和 AUROC 相对于设定 2 分别提升了 5.32 个百分点及 14.93 个百分点,模型性能得到显著提高,验证了难分样本学习策略的有效性。

(4)类原型增强:虽然类原型增强并非本文所提,但叠加该策略后,ACC 和 AUROC 分别提升了 1.36 个百分点及 1.47 个百分点,说明类原型的表征鲁棒性对性能有正向影响。

为更直观地展现不同组件的效果,本文采用 *t*-SNE 降维方法,对消融实验中不同变体的特征空间进行了降维可视化。结果如图 9 所示,其中,不同颜色对应不同目标,黑色为未知类目标,点对应样本特征向量。如图 9(a)所示,细粒度未知类目标与 F-16 因相似性较高,其特征区域更易发生重叠,基准方法的区分效果欠佳。如图 9(b)所示,通过多球体建模提升了未知类与已知类的区分度,但类间仍有混叠。如图 9(c)所示,引入自适应间隔与空间拓扑约束后,类间混叠问题得到显著改善,但细粒度难分样本依旧难以区分。如图 9(d)所示,结合难分样本学习策略,模型学到更精细的差异化特征,类内分布更紧致、类间边界更清晰,提升了细粒度未知类判别能力。

表 5 消融实验结果 单位:%

Table 5 Ablation study results unit:%

设定	多球体建模	自适应间隔与空间拓扑约束	难分样本学习	类原型增强	5-way 10-shot	
					ACC	AUROC
基准方法	×	×	×	×	87.38	53.90
1	√	×	×	×	78.86	73.57
2	√	√	×	×	87.80	79.23
3	√	√	√	×	93.12	94.16
4	√	√	√	√	94.48	95.63

3.5 模型部署与实时性验证

面向硬件资源受限场景,DNN 带来大量的计算与

存储开销,导致其工程应用困难。为验证所提方法在硬件资源受限场景下的工程可实现性,本文采用讯为

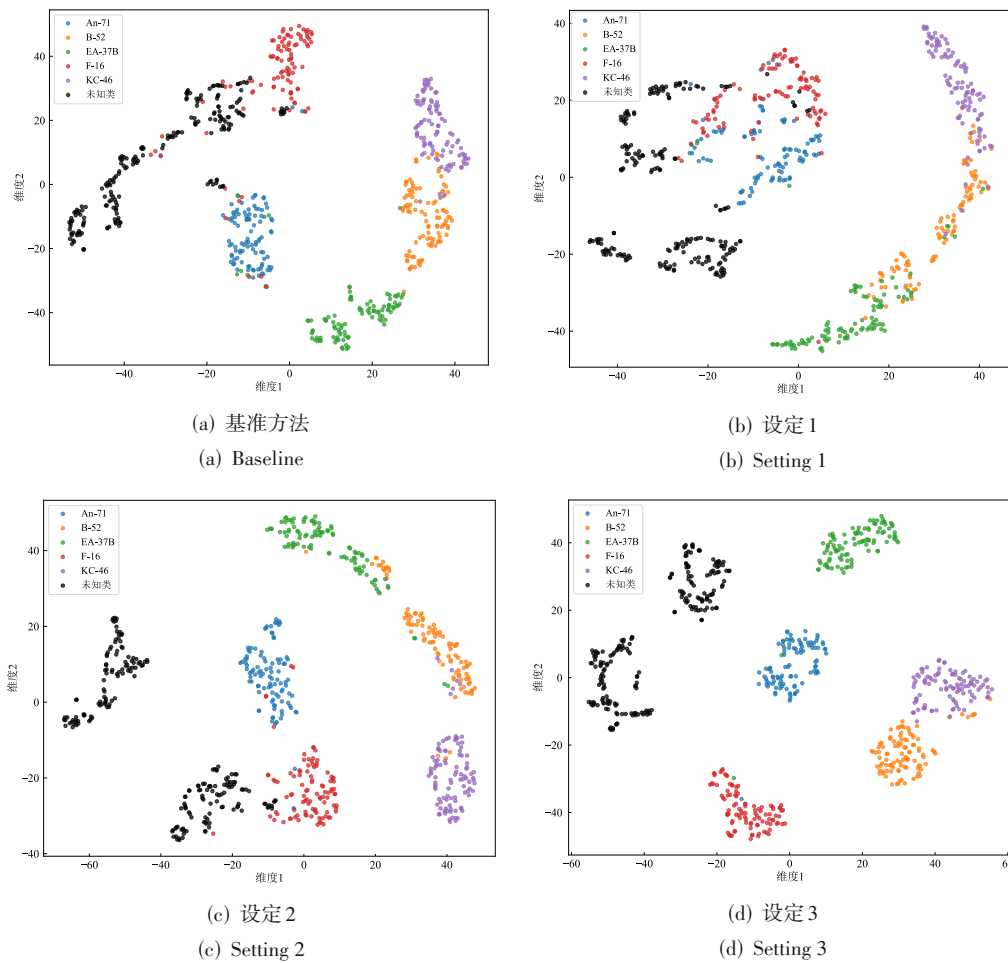


图9 消融实验特征空间可视化结果

Figure 9 Visualization results of the feature space in the ablation study

iTOP-RK3588 开发板^[31]对模型进行嵌入式部署。该开发板搭载了国产化的瑞芯微 RK3588 嵌入式 AI 芯片作为计算核心。实验场景为 5-way 10-shot 细粒度未知类识别。模型部署流程如图 10 所示,分为模型量化与格式转换、推理与评估两部分,模型量化步骤将模型权重从 Float32 全精度格式量化至 Float16 半精度格式,以降低存储与计算开销。模型在板端的部署以及在 PC 端部署的性能对比结果如表 6 所示。可以看出,对模型进行嵌入式部署后,模型准确率 ACC 及 FPR95 精度损失均低于 1%,同时,板端半精度模型推理时延为 2.197 ms,相较于 PC 端降低约 65%,功耗仅为 2.25 W,验证了本文方法在硬件资源受限场景下也具备较好的工程可实现性。

表 6 模型板端部署性能对比

Table 6 Comparison of on-board deployment performance of the model

模型	硬件平台	模型权重位宽/bit	ACC/%	FPR95/%	模型权重/MB	推理时延/ms	吞吐量/FPS	功耗/W
FP32 全精度模型	RTX-3090	32	94.48	6.80	4.38	6.260	159.660	157.00
FP16 半精度模型	瑞芯微 RK3588	16	94.06	7.02	2.19	2.197	455.127	2.25

注:5-way 10-shot, 细粒度未知类包括 AN/ALE 和 BGM-109。

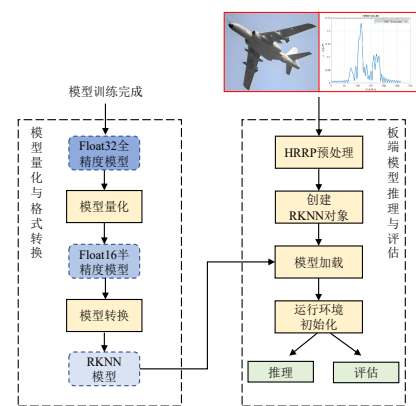


图 10 模型部署与板端评估

Figure 10 Model deployment and evaluation on the hardware platform

4 结论

针对 FSOSR 场景下的雷达 HRRP 目标识别难题, 本文提出了一种基于多球体空间拓扑约束的雷达目标 HRRP FSOSR 方法。通过引入元学习框架缓解少样本场景下模型过拟合问题; 通过多球体建模对未知类分布进行隐式建模, 该建模方式仅通过少量样本便可快速建立决策边界, 且不依赖伪未知样本; 引入自适应间隔约束多球体的空间拓扑关系, 避免球体间的混叠, 提升多球体建模效果以及决策边界的精细度; 结合难分样本学习策略, 学习更精细的差异化特征, 增强对细粒度未知类的判别能力。基于电磁仿真 HRRP 数据的实验结果表明: 所提方法在 5-shot 及 10-shot 场景下, 分类准确率和未知类判别性能均显著优于现有方法, 展现出其稳健的 FSR 能力与良好的泛化性能; 对所提方法在嵌入式硬件平台中进行部署验证, 结果表明模型板端识别精度与 PC 端接近, 且实时性较好。本文方法适用于未知类频发的复杂场景, 可支撑高分辨体制雷达对非合作目标的探测识别; 同时, 得益于良好的工程可实现性, 该方法亦适用于机载平台等高实时性需求、硬件资源受限的应用场景。

参考文献


- [1] 翟颖, 陈渤. 基于稳健变分自编码模型的雷达高分辨距离像目标识别算法[J]. 电子学报, 2020, 48(6): 1149-1155. Zhai Ying, Chen Bo. Robust variational auto-encoder for radar HRRP target recognition[J]. Acta Electronica Sinica, 2020, 48(6): 1149-1155. (in Chinese)
- [2] Wang J J, Liu Z, Ran L, et al. Feature extraction method for DCP HRRP-based radar target recognition via m - χ decomposition and sparsity-preserving discriminant correlation analysis[J]. IEEE Sensors Journal, 2020, 20(8): 4321-4332.
- [3] 廖磊瑶. 基于物理可解释自编码模型的雷达目标方位稳健识别算法[J]. 电子学报, 2024, 52(11): 3847-3857. Liao Leiyao. High-range resolution radar target recognition based on deep interpretable probabilistic auto-encoder model[J]. Acta Electronica Sinica, 2024, 52(11): 3847-3857. (in Chinese)
- [4] Dong G G, Liu H W. A hierarchical receptive network oriented to target recognition in SAR images[J]. Pattern Recognition, 2022, 126: 108558.
- [5] 杨威, 李玮杰, 刘永祥, 等. 基于测地线流式核的雷达目标高分辨距离像鲁棒识别方法[J]. 电子学报, 2023, 51(3): 527-536. Yang Wei, Li Weijie, Liu Yongxiang, et al. Radar target recognition method for HRRP based on geodesic flow kernel[J]. Acta Electronica Sinica, 2023, 51(3): 527-536. (in Chinese)
- [6] Feng B, Chen B, Liu H W. Radar HRRP target recognition with deep networks[J]. Pattern Recognition, 2017, 61: 379-393.
- [7] Du L, Liu H W, Bao Z, et al. Radar HRRP target recognition based on higher order spectra[J]. IEEE Transactions on Signal Processing, 2005, 53(7): 2359-2368.
- [8] Du L, He H, Zhao L, et al. Noise robust radar HRRP target recognition based on scatterer matching algorithm[J]. IEEE Sensors Journal, 2016, 16(6): 1743-1753.
- [9] Li L, Liu Z, Li T. Radar high-resolution range profile feature extraction method based on multiple kernel projection subspace fusion[J]. IET Radar, Sonar & Navigation, 2018, 12(4): 417-425.
- [10] Lundén J, Koivunen V. Deep learning for HRRP-based target recognition in multistatic radar systems[C]//2016 IEEE Radar Conference. Piscataway: IEEE, 2016: 1-6.
- [11] Xu B, Chen B, Wan J W, et al. Target-aware recurrent attentional network for radar HRRP target recognition[J]. Signal Processing, 2019, 155: 268-280.
- [12] Du C, Chen B, Xu B, et al. Factorized discriminative conditional variational auto-encoder for radar HRRP target recognition[J]. Signal Processing, 2019, 158: 176-189.
- [13] 郭泽坤, 田隆, 韩宁, 等. 采用 CNN-SSD 的雷达 HRRP 小样本目标识别方法[J]. 西安电子科技大学学报(自然科学版), 2021, 48(2): 1-14. Guo Zekun, Tian Long, Han Ning, et al. Radar HRRP based few-shot target recognition with CNN-SSD[J]. Journal of Xidian University (Natural Science), 2021, 48(2): 1-14. (in Chinese)
- [14] Huang Y, Wen Y, Shi L C, et al. Recognition-aware HRRP generation with generative adversarial network[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 3503705.
- [15] Liu Q, Zhang X Y, Liu Y X, et al. Few-shot HRRP target recognition based on gramian angular field and model-agnostic meta-learning[C]//2021 IEEE 6th International Conference on Signal and Image Processing. Piscataway: IEEE, 2021: 6-10.
- [16] Guo Z K, Liu Z, Xie R, et al. HRRP few-shot target recognition for full polarimetric radars via SCs optimal matching[J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(2): 4526-4541.
- [17] Chen W, Wang Y H, Song J, et al. Open set HRRP recognition based on convolutional neural network[J]. The

- Journal of Engineering, 2019, 2019(21): 7701-7704.
- [18] Xia Z H, Wang P H, Dong G G, et al. Surrounding prototype loss for radar HRRP open set target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 4027305.
- [19] Li W T, Li S, Tian B, et al. Regularization-based region learning for radar HRRP open set recognition[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 2512615.
- [20] Liu B, Kang H, Li H X, et al. Few-shot open-set recognition using meta-learning[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020: 8795-8804.
- [21] Pal D, Bose S, Banerjee B, et al. MORGAN: Meta-learning-based few-shot open-set recognition via generative adversarial network[C]//2023 IEEE/CVF Winter Conference on Applications of Computer Vision. Piscataway: IEEE, 2023: 6284-6293.
- [22] Wang H Y, Pang G S, Wang P, et al. Glocal energy-based learning for few-shot open-set recognition[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2023: 7507-7516.
- [23] Jeong M, Choi S, Kim C. Few-shot open-set recognition by transformation consistency[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2021: 12561-12570.
- [24] Ye H J, Hu H X, Zhan D C, et al. Few-shot learning via embedding adaptation with set-to-set functions[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020: 8805-8814.
- [25] Zaheer M, Kottur S, Ravanbakhsh S, et al. Deep sets[J]. Advances in Neural Information Processing Systems, 2017, 30.
- [26] Wu C Y, Manmatha R, Smola A J, et al. Sampling matters in deep embedding learning[C]//2017 IEEE International Conference on Computer Vision. Piscataway: IEEE, 2017: 2859-2867.
- [27] Wang X, Han X T, Huang W L, et al. Multi-similarity loss with general pair weighting for deep metric learning[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2019: 5017-5025.
- [28] Ruff L, Vandermeulen R, Goernitz N, et al. Deep one-class classification[C]//International conference on machine learning. Cambridge: PMLR, 2018: 4393-4402.
- [29] Snell J, Swersky K, Zemel R. Prototypical networks for few-shot learning[J]. Advances in Neural Information Processing Systems, 2017, 30.
- [30] Tax D M J, Duin R P W. Support vector data description[J]. Machine Learning, 2004, 54(1): 45-66.
- [31] 唐金龙. 基于图神经网络的雷达一维距离像识别[D]. 杭州: 杭州电子科技大学, 2023.
Tang Jinlong. Radar One-Dimensional Range Profile Target Recognition Based on Graph Neural Network[D]. Hangzhou: Hangzhou Dianzi University, 2023. (in Chinese)

作者简介



徐寒铮 男, 2000年1月出生于福建省宁德市。现为西安电子科技大学博士研究生。主要研究方向为雷达自动目标识别、深度学习、模式识别和小样本学习。中国电子学会会员编号: E190185703A。
E-mail: 24021110921@stu.xidian.edu.cn



刘 峥 男, 1964年3月出生于陕西省咸阳市。现为西安电子科技大学雷达信号处理国家重点实验室教授、博士生导师。主要研究方向为雷达信号处理的理论与系统设计、雷达精确制导技术、多传感器协同探测与信息融合等。
E-mail: lz@xidian.edu.cn



许述文 男, 1985年11月出生于安徽省黄山市。现为西安电子科技大学雷达信号处理国家重点实验室副主任、教授、博士生导师。主要研究方向为雷达目标检测、机器学习、时频分析和 SAR 图像处理。中国电子学会会员编号: E190012872S。
E-mail: swxu@mail.xidian.edu.cn



郭泽坤 男, 1994年8月出生于陕西省咸阳市。现为西安电子科技大学博士研究生。主要研究方向为雷达目标识别、深度学习、小样本学习。
E-mail: zkguo@xidian.edu.cn