

基于最优传输的全极化雷达 HRRP 非均衡小样本目标识别方法

高欣宇¹ 李璐¹ 侯小盈¹

GAO Xinyu LI Lu HOU Xiaoying

摘要

针对雷达高分辨距离像(HRRP)在小样本条件下对非合作目标识别难,并且现有方法对目标极化散射信息利用不充分的问题,文章提出一种基于最优传输的全极化雷达 HRRP 非均衡小样本目标识别方法。该方法首先利用 Cameron 分解提取全极化 HRRP 在多种标准散射基上更加精细的投影分量;其次,利用库内目标投影分量训练基模型作为特征提取器;然后,利用特征提取器提取库外目标的特征,并利用幂变换使所提取特征服从高斯分布,利用最优传输方法获取库外目标特征的最优类别中心;最后,利用近邻方法实现库外目标分类。实验部分利用 10 类民用车辆全极化 HRRP 数据基于狄利克雷分布构建非均衡测试集进行实验验证,结果表明,所提方法能够充分利用目标极化散射特性,并有效提高非完备样本条件下目标识别的准确率。

关键词

全极化雷达;自动目标识别;小样本学习;最优传输;高分辨距离像

doi: 10.3969/j.issn.1672-9528.2026.05.002

0 引言

高分辨距离像(high resolution range profile, HRRP)是由宽带雷达信号获取的目标散射中心子回波沿雷达射线投影的向量和,包含目标重要的结构及尺寸等特征^[1]。HRRP 的极化特征能够反映目标的结构信息、表面粗糙度、对称性等特性,是雷达目标识别的重要特征。

雷达 HRRP 小样本目标识别技术已经成为广泛研究的热点问题,文献[2]提出一种基于多任务学习的因子分析小样本识别方法(factor analysis, FA),该方法采用功率谱特征进行建模,是典型的人工特征提取方法,此类方法在提取低维度特征的时候或多或少存在可分性信息的损失。文献[3]提出一种采用自适应高斯分类器(adaptive gaussian classifier, AGC)对 HRRP 进行建模的方法,该方法所需样本量较少,但对数据的表征能力有限。文献[4]提出一种多任务稀疏学习的统计建模方法,通过挖掘不同任务间共享的结构信息降低了模型对数据量的需求,有效提高了模型在小样本条件下的识别能力,但该方法为浅层统计模型,模型对数据的特征学习能力有限。文献[5]提出一种基于时间序列的 TCNN 模型,通过该模型挖掘 HRRP 时域序列特征信息,以此提高模型所学特征的表征能力,但模型训练需要具备一定的样本量,在

小样本情况下识别能力受限。文献[6]提出一种多极化融合的小样本 HRRP 识别方法,该方法基于元学习进行建模,实现了对于库内目标在不同极化方式下的快速泛化,但该模型依然属于闭集识别方法。文献[7-9]提出一种 Cameron 分解与极限学习机融合的全极化 HRRP 识别方法,该方法有效提升了所得特征的可分性和噪声稳健性,但该方法仍然基于样本完备的假设,在小样本条件下,其识别能力受限。

考虑到现有方法所存在的不足,本文基于最优传输提出一种全极化雷达 HRRP 非均衡小样本目标识别方法,利用 Cameron 分解获取全极化 HRRP 更加精细的投影分量,利用幂变换使所提取特征服从高斯分布,利用最优传输获取最优类别中心,进而提升模型对小样本目标的识别能力,为了验证更加接近实际情况,本文基于狄利克雷分布构建测试集进行模型验证。

1 全极化雷达 HRRP 非均衡小样本目标识别方法

本方法旨在通过完备的库内目标样本训练基模型,通过库外目标构建支持集(小样本集)和查询集,通过基模型对支持集提取特征,基于最优传输算法通过所提取特征计算最优类别中心,并对查询集进行分类,实现库外小样本目标识别。

1.1 小样本目标识别任务定义

本文定义库内目标样本为 D_{base} , 库外非合作目标样本为 D_{novel} , D_{base} 中包含 C_1 类目标, D_{novel} 包含 C_2 类目标, $C_1 \cap C_2 = \emptyset$ 。基于 D_{novel} 构建元测试集 D_{mte} , D_{mte} 包含一组支持

1. 中国航空工业集团公司西安航空计算技术研究所
陕西西安 710068

集 S 和查询集 Q , 本文旨在通过 D_{base} 所训练的基模型 f_θ 对 S 进行特征提取, 利用所提取特征得到初始类别中心, 利用最优传输得到最适当当前库外目标小样本集的最优类别中心, 并实现目标分类。

$$\arg \min L_{\text{cc}} \left(\text{OT} \left(\frac{1}{K} \sum_K f_s; \varphi_{\text{base}}, Q \right) \right) \quad (1)$$

式中: φ_{base} 为基模型的参数, $\text{OT}(\cdot)$ 为最优传输算法, L_{cc} 为损失函数, f_s 为基模型 f_θ 所提取 S 的特征集, K 为 S 中的样本量。所得最优类别中心需要 Q 具备最优分类能力。

1.2 基模型预训练

本文首先通过 Cameron 分解提取 $D_{\text{base}} = \{X_i, y_i\}_{i=1}^B$ 全极化 HRRP 在标准散射基上更加精细的投影分量 $\{X_i^c, y_i\}_{i=1}^B$, B 为 D_{base} 样本量, 利用所提取投影分量训练基模型, 该过程用公式表示为:

$$\varphi_{\text{base}} = \arg \min_{\varphi_{\text{init}}} \frac{1}{B} \sum_{i=1}^B L_{\text{cc}}(X_i^c, y_i; \varphi_{\text{init}}) \quad (2)$$

式中: φ_{init} 为初始化的模型参数, φ_{base} 为训练完成的基模型参数。后续步骤中, 固定参数 φ_{base} , 利用基模型对库外目标样本进行特征提取。

1.3 基于最优传输的非均衡小样本目标分类

利用 Cameron 分解获取库外目标全极化 HRRP 小样本集的投影分量, 通过所训练基模型提取投影分量特征, 为了使特征服从高斯分布, 本文利用幂变换对特征进行规范化处理, 用公式表示为:

$$f'_{\text{novel}} = \text{PT}(f_{\text{novel}}) = \frac{(f_{\text{novel}} + \varepsilon)^\alpha}{\left\| (f_{\text{novel}} + \varepsilon)^\alpha \right\|_2}, \alpha \neq 0 \quad (3)$$

式中: f_{novel} 为所提取库外目标特征, f'_{novel} 为变换后的特征, $\varepsilon = 1\text{e-}6$ 为使 $f_{\text{novel}} + \varepsilon$ 绝对为正。

对于基于度量学习的分类方法, 特别是在小样本场景下, 较优的类别中心对准确预测有很大帮助, 本文利用最大后验概率计算库外目标类别中心, 该过程等价于最小化 Wasserstein 距离, 最小化 Wasserstein 距离就是优化特征向量初始分布到类高斯分布的最优传输过程。需要优化的目标函数用公式表示为:

$$\{t'(f_i)\}, \{c'_j\} = \arg \max_{\{t(f_i)\} \in C, \{c'_j\}} \prod_i P(f_i | j = t(f_i)) = \arg \min_{\{t(f_i)\} \in C, \{c'_j\}} \sum_i (f_i - c_{t(f_i)})^2 \quad (4)$$

式中: C 为可能出现的类别, f_i 为特征向量, c_j 为预测类别 j , $t(f_i)$ 为响应的类别标签。

此处采用 Sinkhorn 算法^[10] 通过迭代最小化 Wasserstein 距离, 用公式表示为:

$$M' = \text{Sinkhorn}(L, p, q, \beta) = \arg \min_{M \in U(p, q)} \sum_{ij} M_{ij} L_{ij} + \beta H(M) \quad (5)$$

式中: $U(p, q)$ 为正矩阵, 矩阵 M 为分类的所有测试样本的分类概率分布, p 为矩阵 M 行和, q 为矩阵 M 列和, L_{ij} 为距离度量函数, $H(M)$ 为矩阵的熵, $H(M) = -\sum_{ij} M_{ij} \log M_{ij}$ 。利

用式 (5) 对每个 Q 得到一个映射矩阵 M' , 利用 M' 计算新的类别中心, 用公式表示为:

$$\hat{c}_j = g(M', j) = \frac{\sum_{i=1}^{nq} M'_{ij} f_i + \sum_{f \in f_s} f}{s + \sum_{i=1}^{nq} M'_{ij}} \quad (6)$$

式中: n 为查询集类别数, q 为查询集样本量, s 为支持集样本量, f 为查询集 Q 和支持集 S 所提取的特征集, $\hat{c}_j$ 为所计算的新类别中心。利用所获取的新类别中心更新原初始化类别中心, 用公式表示为:

$$c_j = c_j + \gamma(\hat{c}_j - c_j) \quad (7)$$

式中: c_j 为初始化的类别中心, 其计算方法为 $c_j = \frac{1}{K} \sum_{k=1}^K f_s$, γ 为类别中心更新的学习率。在通过上述多次迭代过程之后, 得到最优类别中心 c_j^{op} , 利用最优类别中心获取分类概率分布, 用公式表示为:

$$P(y = t(f_j) | Q) = \frac{\exp(-d(f(Q), c_j^{\text{op}}))}{\sum_q \exp(-d(f(Q), c_q^{\text{op}}))} \quad (8)$$

式中: $d(\cdot)$ 为欧氏距离度量函数, y 为当前所预测类别, $t(f_j)$ 为当前样本标签。

2 实验结果与分析

2.1 实验数据

本文采用电磁仿真的十类民用车辆全极化雷达 HRRP 电磁仿真数据^[11] 进行实验, 如图 1 所示, 分别为部分民用车辆光学图像和 HH、HV 和 VV 极化方式下的 HRRP。本文选取以 9.6 GHz 为中心的 64 个频率合成目标的极化 HRRP, 合成带宽为 670 MHz。每个极化方式下有 2 880 个样本, 每个样本有 64 个距离单元。




图 1 类民用车辆及其 HH、HV 和 VV 极化方式下的 HRRP 数据

2.2 实验设置

针对 HRRP 的幅度敏感性问题, 本文对 HRRP 做 L_2 范数归一化处理^[12]。针对 HRRP 的平移敏感性的问题, 本文对

HRRP 做重心对齐处理^[13]。从十类民用车中随机选取 7 类作为库内目标, 剩余 3 类为库外目标。元测试集构建 2 000 组元任务, 每个元任务包括支持集和查询集, 其中支持集为“3 类 - k 样本”的形式, k 取 1、5 分别进行试验。现有的基于元学习的小样本目标识别方法其查询集多基于均匀分布进行随机抽取, 每个类别的样本等量, 为了使模型验证过程更加接近实际情况, 本文基于狄利克雷分布构建查询集, 查询集每个类别的样本量非均衡, 且均从其所属类别的 2 880 个样本中随机抽取。

本实验采用一维 ResNet-12 网络进行模型训练, 优化器采用 SGD, 初始学习率为 0.001, 总迭代次数为 200。

2.3 实验结果分析

为了验证本文方法的有效性, 本节分别选取多种方法在小样本条件下进行了定量和定性的识别性能对比。表 1 为不同对比方法与本文所提方法 OTFPR 分别在 1、5、10、15、20 样本所得分类准确率。由表 1 可得, 在 1 样本条件下 SVM、Logistic 以及 PCA-Logistic 等方法分类准确率均在 42% 左右, 而所提方法 OTFPR 达到了 86.08% 的识别准确率, 相对提升了 44% 左右; 在 5 样本条件下, 本文所提方法达到了 93.42% 的识别准确率; 在 10 样本条件下, 分类准确率提高到了 95% 以上; 在 20 样本条件下, 本文所提方法达到了 97.42% 的识别率。与 SVM 方法相比, 在 1、5、10、15、20 样本条件下, 本文所提方法识别率分别提升了 42.81%、37.03%、36.95%、35.87%、24.39%。

表 1 HH-HV-VV 全极化下不同方法分类准确率定量对比

方法	2 000 Tasks				
	1-shot	5-shot	10-shot	15-shot	20-shot
SVM	43.27	56.39	58.65	60.97	73.03
PCA-SVM	45.84	58.23	64.33	68.09	74.66
Logistic	43.13	57.38	65.48	68.54	72.82
CNN-SVM	61.25	71.97	80.85	81.77	83.34
CNN-Logistic	62.41	72.82	78.76	79.92	81.28
OTFPR	80.08	93.42	95.60	96.84	97.42

在 PCA 降维后, 通过 SVM 分类, 准确率略微有所提升, 对于全极化 HRRP, 传统的方法如 SVM 等分类准确率相对神经网络的方法往往比较低, 这是因为在没有手动特征提取的情况下, 全极化数据共同分类加大了数据分类难度, 数据可分性降低。从表 1 可得, 在 CNN 特征提取之后, 将所得特征利用 SVM 以及 Logistic 分类, 此类非端到端方法所得分类准确率较为相近, 但与本文所提方法相比其识别率在 1、5、10、15、20 样本条件下, 依然较低, 本文所提方法从 5 样本开始, 分类准确率均在 90% 以上, 由此可见, 本文所提方法充分利用了 HRRP 全极化特征信息, 有效提升了模型泛化性能。

如图 2 所示, 为 HH、HV、VV 三种单极化方式和全极化方式下, OTFPR 和 SVM 两种方法的分类准确率对比图。图 2 (a) 为本文所提 OTFPR 方法, 三种单极化条件下, 其分类性能相近, 变化趋势也基本相似, 而在全极化方式下, 模型识别准确率大幅度提升, 在 1 样本条件下即达到了 85% 以上。图 2 (b) 为 SVM 分类方法, 三种单极化方式下, 模型识别性能相近, 其中 HH 极化方式下的识别准确率比 HV 和 VV 极化方式下的识别准确率略低, 而在全极化条件下, 识别准确率仅略微提升。由此可得, 本文所提方法相对于传统方法能够充分利用 HRRP 极化特征信息, 所训练模型泛化性能更强。




图 2 多种极化方式下 OTFPR 及 SVM 准确率对比

图 3 为不同方法特征空间 t-SNE^[14] 降维可视化散点图, 由图可得, SVM 分类所得到的散点图聚合性较差, 不同类别之间的特征点分布最为杂乱, PCA-SVM 分类所得散点的聚合性略微提升, 但依然存在较多特征点分布杂乱, 易于造成模型错分。而 CNN-SVM 分类所得到的散点图分布整体性有所提升, 但类内聚合性依然较差。而本文所提方法 OTFPR 的特征点类内聚合性最佳, 类间分布最为整齐, 不同库外目标特征点边界清晰, 因此, 可以从定性的角度进一步证明, 本文所提方法在小样本条件下, 对库外目标泛化性能最强。




图 3 模型特征空间 t-SNE 降维可视化

如图 4 所示, 本文绘制了不同模型在小样本条件下的 ROC (receiver operating characteristic) 曲线。图中三条不带散点的阶梯曲线分别表示模型对三个库外目标类别的识别结

果,其曲线下面积 AUC (area under curve) 用于衡量对应类别的判别能力。一般而言,AUC 越大,说明模型对该类别的区分能力越强。两条带散点的虚线分别表示微观均值和宏观均值 ROC 曲线,用于从整体层面评价模型在三个类别上的平均识别性能。从图 4 可以看出,本文所提方法的 ROC 曲线整体更靠近左上角,且与横轴围成的面积相对较大,说明该方法在小样本条件下具有更好的目标识别能力。相比之下,SVM 方法对应的 ROC 曲线下面积较小,表明其在有限样本条件下的类别判别能力相对较弱。结合图 3 中的特征分布可以进一步观察到,可分性较好的类别对应的 ROC 曲线通常具有更高的 AUC;而特征边界存在混叠的类别,其 ROC 曲线提升幅度相对有限。上述结果表明,本文所提方法能够在小样本场景下有效提高库外目标类别的识别性能。




图 4 ROC 曲线

3 总结

为了提高模型在小样本条件下对非合作目标 HRRP 的泛化能力,本文提出了一种基于最优传输的全极化雷达 HRRP 非均衡小样本目标识别方法。该方法通过类别多样化的完备库内目标训练集训练基模型作为特征提取器,对所提取的库外目标特征进行幂变换,并计算初始化类别中心,通过最优传输方法得到最优类别中心,利用近邻方法进行分类。基于电磁仿真数据开展了实验验证,结果证明,所提方法能够充分学习目标极化特征信息,并且有效提高了模型在小样本条件下对非合作目标的识别性能。

参考文献:

- [1] 胡明春,王建明,孙俊,等.雷达目标识别原理与实验技术[M].北京:国防工业出版社,2017:12-13.
- [2] 徐丹蕾.基于稀疏贝叶斯学习的雷达自动目标识别方法研究[D].西安:西安电子科技大学,2015.
- [3] Jacobs S P, O'Sullivan J A. Automatic target recognition using

high-resolution radar range-profiles [J]. IEEE Transactions on Aerospace and Electronic Systems,2000,36(2):364 - 381.

- [4] 徐丹蕾,杜兰,王鹏辉,等.采用多任务稀疏学习的雷达 HRRP 小样本目标识别[J].西安电子科技大学学报,2016,43(2): 23-28.
- [5] Wan Jinwei, Chen Bo, Xu Bin, et al. Convolutional neural networks for radar HRRP target recognition and rejection[J/OL]. EURASIP Journal on Advances in Signal Processing, 2019[2026-05-06].<https://link.springer.com/article/10.1186/s13634-019-0603-y>.
- [6] Liu Qi, Zhang Xinyu, Liu Yongxiang, et al. Multi-polarization fusion few-shot HRRP target recognition based on meta-learning framework[J]. IEEE Sensors Journal, 2021,21(16):18085 - 18100.
- [7] 王晶晶,刘峥,谢荣,等.联合 Cameron 分解和融合 RKELM 的全极化 HRRP 目标识别方法[J].雷达学报,2021,10(6): 944-955.
- [8] Lee J S, Pottier E. 极化雷达成像[M].北京:电子工业出版社,2022:159-166.
- [9] Cameron W L, Youssef N N, Leung L K. Simulated polarimetric signatures of primitive geometrical shapes[J]. IEEE Transactions on Geoscience and Remote Sensing, 1996, 34(3): 793-803.
- [10] Cuturi M. Sinkhorn distances: lightspeed computation of optimal transportation distances[PP/OL]. (2013-06-04)[2026-05-06].<https://doi.org/10.48550/arXiv.1306.0895>.
- [11] Dungan K E, Austin C, Nehrbass J, et al. Civilian vehicle radar data domes[C]//Algorithms for Synthetic Aperture Radar Imagery XVII.Bellingham: SPIE,2010: 76990P.
- [12] Du Lan, Liu Hongwei, Bao Zheng. Radar HRRP statistical recognition: parametric model and model selection[J]. IEEE Transactions on Signal Processing, 2008, 56(5):1931-1944.
- [13] 陈渤,刘宏伟,保铮.基于三种不同绝对对齐方法的分类器分析[J].现代雷达,2006(3): 58-62.
- [14] Laurens V D M, Hinton G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(86):2579-2605.

【作者简介】

高欣宇(1995—),女,陕西榆林人,硕士,研究方向:模式识别、目标检测与识别、数字信号处理。

李璐(1994—),女,陕西周至人,硕士,研究方向:目标检测与识别。

侯小盈(1994—),女,陕西渭南人,硕士,研究方向:目标检测与识别。

(收稿日期:2025-10-24 修回日期:2026-05-13)