

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

杨威, 李玮杰, 刘永祥, 黎湘

(国防科技大学电子科学学院, 湖南长沙 410073)

摘要: 非合作目标识别常常面临少量不完备的训练样本、训练样本与测试样本信噪比不一致等现象, 本文为此提出了一种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. 该方法沿格拉斯曼流形中测地线积分提取不变特征, 且通过核函数映射可获得解析特征提取表达式. 该方法还可作为预处理手段对数据降噪, 进一步提高其他算法的识别准确率. 实验结果表明, 对于信噪比失配和少量不完备样本等问题, 该方法都具有鲁棒目标识别能力, 并且满足实时性要求.

关键词: 雷达目标识别; 高分辨距离像; 测地线流式核; 迁移学习; 信噪比失配

基金项目: 国家自然科学基金(No.61871384, No.61401486, No.61921001); 湖南省自然科学基金(No.2017JJ3367)

中图分类号: TN957.51

文献标识码: A

文章编号: 0372-2112(2023)03-0527-10

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

DOI: 10.12263/DZXB.20211574

Radar Target Recognition Method for HRRP Based on Geodesic Flow Kernel

YANG Wei, LI Wei-jie, LIU Yong-xiang, LI Xiang

(College of Electronic Science and Engineering, National University of Defense Technology, Changsha, Hunan 410073, China)

Abstract: Non-cooperative target recognition often faces a small number of incomplete training samples, and inconsistent signal-to-noise ratio (SNR) between training samples and test samples. A robust radar target recognition method for high resolution range profile (HRRP) based on geodesic flow kernel is proposed in this paper. It extracts invariant features along the geodesic integral in the Grassman manifold, and has an analytical expression through kernel function mapping. The method also can be used as a preprocessing tool to reduce data noise and improve the recognition performance of other algorithms. Experimental results show that the proposed method has robust recognition ability for SNR mismatch and a small number of incomplete samples, and meets the requirements of real-time.

Key words: radar target recognition; high resolution range profile; geodesic flow kernel; transfer learning; SNR mismatch

Foundation Item(s): National Natural Science Foundation of China (No.61871384, No.61401486, No.61921001); National Science Foundation of Hunan Province (No.2017JJ3367)

1 引言

近年来, 基于深度学习的高分辨距离像 (High Resolution Range Profile, HRRP) 雷达目标识别方法发展迅速^[1], 但对非合作目标识别的泛化性能还值得深入探索. 非合作目标识别存在信噪比失配和少量不完备样本问题^[2], 即训练集与测试集信噪比不匹配、训练集样本量少且在姿态角等方面不完备, 使得训练和测试集难以服从相同分布.

针对少量不完备样本的 HRRP 识别问题, 目前主要包括迁移学习类^[3-6]和数据生成类方法^[7], 如样本量少^[4, 5, 7]、姿态角不完整^[3, 6]的情况. 针对信噪比失配的 HRRP 识别问题, 可通过提取噪声稳健特征或移除噪声分量^[2]来降低噪声影响, 而鲁棒性识别算法有估计测试样本的信噪比与不同信噪比训练样本的统计模型进行模板匹配^[8]、利用数据增强和改进深度学习网络结构实现低信噪比鲁棒性识别^[9]和基于深度迁移学习研究不

同信杂比海面舰船识别^[10, 11]. 以上研究并未讨论小样本情况下的低信噪比(如 0 dB 以下)识别问题, 并且文献[8]和文献[9]需要一定的先验知识构造训练集. 本文作者前期通过构造含噪数据集实现鲁棒性识别^[9], 可使得深度学习模型记住噪声特征, 并具有一定泛化能力, 但并不能达到提取具有噪声稳健特征的目的. 如图 1 所示, 图 1(a) 为按时间排序的含噪 HRRP 序列, 每一行表示一个 HRRP 样本. 利用文献[12]提出的归因方法, 对不同训练方式的卷积神经网络, 可得到如图 1(b) 和图 1(c) 所示的二值化显著性图. 由此可以看出, 尽管测试集识别率得到了提升, 但含噪训练集得到的深度学习模型对噪声的抑制并不明显. 此外, 由于深度学习为端到端的映射过程, 采用深度迁移学习同样存在可解释性差的问题, 需要分析模型是否提取到了噪声稳健性特征. 特别是在识别应用风险控制要求较高的场景中, 对算法的可解释性有较高要求.




图 1 不同数据训练的模型对于含噪样本识别的显著性图

本文受传统雷达信号处理中主成分分析(Principal Component Analysis, PCA)^[13]和平均距离像^[14]方法的启发, 采用传统迁移学习中几何特征变换方法进行的研究. 假设不同信噪比的样本特征分布在同一流形上, 信噪比的改变导致样本在流形上发生移动, 如何提取对这一过程满足不变性的特征是本文所要研究的问题. 在格拉斯曼流形(Grassman manifold)上, 基于核函数可以高效地表示和求解特征变换^[15], 并且格拉斯曼流形子空间表示可以弥补缺失数据^[15], 能够有效克服小样本问题. 采用格拉斯曼流形中的测地线流式核(Geodesic Flow Kernel, GFK)^[16]函数提取这一过程中的不变特征, 有望较好地解决信噪比失配问题. 总体思路是首先通过 PCA 降维到子空间, 不同信噪比样本集构成的子空间可被视为格拉斯曼流形上的两个点, 两点之间的测地线方程投影模拟特征域的几何和统计特性变化, 通过沿测地线对投影内积分得到对这一过程具有统计平均意义上的不变性特征.

文献调研表明, 本文首次在雷达 HRRP 目标识别领域中引入测地线流式核, 该方法相较于深度学习相比具有如下明显优势: 一是提取了数据的不变特征, 无需噪声的统计先验知识, 且具有解析形式, 可解释性好;

二是样本需求量少, 实时性好, 对噪声变化具有鲁棒性; 三是具有可扩展性, 能作为数据预处理手段对数据降噪提高其他识别算法性能. 大量实验分析验证了上述结论.

2 格拉斯曼流形基础

格拉斯曼流形及测地线流式核的基础知识, 包括格拉斯曼流形的定义、主角度距离度量方法及测地线流式核的计算.

2.1 格拉斯曼流形的定义

定义 1 格拉斯曼流形 $\mathcal{G}(d, D)$ 是 \mathbf{R}^D 的 d 维线性子空间集合, 其中 \mathbf{R} 表示实数集.

$\mathcal{G}(d, D)$ 是一个 $d(D-d)$ 维的紧黎曼流形^[17, 18], 每一个元素可用一个正交基矩阵 $\mathbf{Y} \in \mathbf{R}^{D \times d}$ 表示. \mathbf{Y} 是 \mathbf{R}^D 空间中的 d 个基向量, 其中 $\mathbf{Y}^T \mathbf{Y} = \mathbf{I}_d$, \mathbf{I}_d 为 d 维单位矩阵. 如式(1)所示, 由 PCA 得到的特征向量集, 按照对应特征值由大至小排列, 构成正交矩阵为 $\mathbf{P} \in \mathbf{R}^{D \times D}$, 由该矩阵前 d 列构成的子阵 $\hat{\mathbf{P}} \in \mathbf{R}^{D \times d}$ 可作为格拉斯曼流形矩阵, 即 $\mathbf{Y} = \hat{\mathbf{P}}$. 其中, $\mathbf{X} \in \mathbf{R}^{n \times D}$ 为 n 个 D 维向量组成的去中心化零均值数据集, \mathbf{C} 为协方差矩阵, \mathbf{L} 和 \mathbf{P} 分别为对应的特征值矩阵和特征向量矩阵. 若 \mathbf{Y}_1 和 \mathbf{Y}_2 相同, 当且仅当 $\text{span}(\mathbf{Y}_1) = \text{span}(\mathbf{Y}_2)$, 即列向量张成的子空间相同. 因此, $\mathcal{G}(d, D)$ 中的每一个元素为正交基矩阵 \mathbf{Y} 张成的子空间, 其矩阵表示并不唯一, 这在一定程度上可以提高对于数据不足的鲁棒性.

$$\mathbf{C} = \frac{1}{n} \mathbf{X}^T \mathbf{X} = \mathbf{P} \mathbf{L} \mathbf{P}^T \quad (1)$$

2.2 格拉斯曼流形的主角度距离度量

定义 2 $\mathbf{Y}_1, \mathbf{Y}_2 \in \mathbf{R}^{D \times d}$ 为两个不同的正交矩阵, 子空间 $\text{span}(\mathbf{Y}_1)$ 和 $\text{span}(\mathbf{Y}_2)$ 之间主角度 (principal angles)^[19] $0 \leq \theta_1 \leq \dots \leq \theta_d \leq \pi/2$ 的递归定义如式(2)所示, 即两个子空间所有的单位向量对按相似性排序构成主角度.

$$\cos \theta_k = \max_{\mathbf{u}_k \in \text{span}(\mathbf{Y}_1)} \max_{\mathbf{v}_k \in \text{span}(\mathbf{Y}_2)} \mathbf{u}_k^T \mathbf{v}_k \quad (2)$$

如式(3)所示, 可利用奇异值分解(Singular Value Decomposition, SVD) 计算主角度 $\theta_1, \dots, \theta_d$, 其中奇异值对角矩阵 $\cos \boldsymbol{\Theta} = \text{diag}(\cos \theta_1, \dots, \cos \theta_d)$, \mathbf{U} 和 \mathbf{V} 为 d 阶正交矩阵.

$$\mathbf{Y}_1^T \mathbf{Y}_2 = \mathbf{U}(\cos \boldsymbol{\Theta}) \mathbf{V}^T \quad (3)$$

黎曼流形中通常使用测地线距离衡量两点之间差异性. 对于格拉斯曼流形而言, 可基于主角度衡量格拉斯曼流形上两个子空间 \mathbf{Y}_1 和 \mathbf{Y}_2 间的距离, 测地线距离与主角度的关系^[18, 20] 为 $d_G^2(\mathbf{Y}_1, \mathbf{Y}_2) = \sum_i \theta_i^2$. 因此, 文献[15]基于主角度提出多种子空间距离度量方法, 文献[16]使用的是最小相关(min correlation) 距离如式(4)所示.

$$d_{\min}(\mathbf{Y}_1, \mathbf{Y}_2) = (1 - \cos^2 \theta_d)^{1/2} = \sin \theta_d \quad (4)$$

2.3 测地线流式核

假设 n 个 D 维向量组成的源域数据集为 $\mathcal{S} \in \mathbf{R}^{n \times D}$, m 个 D 维向量组成的目标域数据集为 $\mathcal{T} \in \mathbf{R}^{m \times D}$, 两者数据集的混合为 $\mathcal{S} + \mathcal{T} \in \mathbf{R}^{(n+m) \times D}$. 文中除特殊说明外, 源域为带标签的训练集, 目标域为无标签的测试集. 在格拉斯曼流形理论框架下, 要完成对无标签数据集的分类识别, 其核心在于怎样构建格拉斯曼流形, 以及如何度量流形空间中不同点的距离. GFK 技术是解决上述问题的有效途径, 其关键在于测地线投影积分的构建和求解, 主要分为两步, 一是确定最优的格拉斯曼流形维度, 二是构建 GFK 映射.

为了确定最优的格拉斯曼流形维度 d , 即 PCA 降维的最优子空间矩阵 \mathbf{Y} 的维度, 测地线流式核首先定义了子空间不一致性度量 (Subspace Disagreement Measure, SDM). 利用如式 (1) 所示的 PCA 降维方法, 获得源域、目标域及两者混合数据集的 d 维格拉斯曼流形矩阵, 并进一步张成三个子空间 $\text{PCA}_{\mathcal{S}}$ 、 $\text{PCA}_{\mathcal{T}}$ 和 $\text{PCA}_{\mathcal{S}+\mathcal{T}}$, 不同子空间的 SDM 计算如式 (5) 所示, 其中 $\sin \alpha_d$ 为 $\text{PCA}_{\mathcal{S}}$ 和 $\text{PCA}_{\mathcal{S}+\mathcal{T}}$ 的最小相关距离, $\sin \beta_d$ 为 $\text{PCA}_{\mathcal{T}}$ 和 $\text{PCA}_{\mathcal{S}+\mathcal{T}}$ 的最小相关距离, α_d 和 β_d 为对应的主角度, 上述三个子空间都属于 $\mathbf{R}^{D \times d}$. 文献 [16] 使用了满足式 (6) 的最小值作为最优格拉斯曼流形维度. 这是由于 $D(d)=1$ 以后增加 d , 两个子空间有正交方向 ($\alpha_d = \beta_d = \pi/2$) [16], 不利于不同域之间方差转移, 而尽可能高的 d 可以更好地保留源域方差构建良好的识别器.

$$D(d) = 0.5[\sin \alpha_d + \sin \beta_d] \quad (5)$$

$$d^* = \min \{D(d) = 1\} \quad (6)$$

以 $\text{PCA}_{\mathcal{S}}$ 和 $\text{PCA}_{\mathcal{T}}$ 的两组基 $\mathbf{P}_{\mathcal{S}}$ 和 $\mathbf{P}_{\mathcal{T}}$ 为基础, 式 (7) 定义了两组基之间的测地线方程 $\Phi(t)$ [16], $\Phi(0) = \mathbf{P}_{\mathcal{S}}$, $\Phi(1) = \mathbf{P}_{\mathcal{T}}$, 即源域和目标域分别在于测地线的起点和终点, 其余 $t \in (0, 1)$ 所对应方程 $\Phi(t) \in \mathcal{G}(d, D)$ 为流形空间中一点. $\mathbf{R}_{\mathcal{S}} \in \mathbf{R}^{D \times (D-d)}$ 为 $\mathbf{P}_{\mathcal{S}}$ 的正交补, \mathbf{U}_1 和 \mathbf{U}_2 分别由式 (8) 和式 (9) 的 SVD 得到, Γ 对角阵元素为 $\cos \theta_i$, Σ 对角阵元素为 $\sin \theta_i$, θ_i 为主角度, $\Gamma(t)$ 和 $\Sigma(t)$ 对角线元素分别为 $\cos(t\theta_i)$ 和 $\sin(t\theta_i)$.

$$\begin{aligned} \Phi(t) &= \mathbf{P}_{\mathcal{S}} \mathbf{U}_1 \Gamma(t) - \mathbf{R}_{\mathcal{S}} \mathbf{U}_2 \Sigma(t) \\ &= [\mathbf{P}_{\mathcal{S}} \quad \mathbf{R}_{\mathcal{S}}] \begin{bmatrix} \mathbf{U}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{U}_2 \end{bmatrix} \begin{bmatrix} \Gamma(t) \\ \Sigma(t) \end{bmatrix} \end{aligned} \quad (7)$$

$$\mathbf{P}_{\mathcal{S}}^T \mathbf{P}_{\mathcal{T}} = \mathbf{U}_1 \Gamma \mathbf{V}^T \quad (8)$$

$$\mathbf{R}_{\mathcal{S}}^T \mathbf{P}_{\mathcal{T}} = -\mathbf{U}_2 \Sigma \mathbf{V}^T \quad (9)$$

测地线方程的投影 $\mathbf{z} = \Phi(t)^T \mathbf{x}$ 描述了输入 D 维特征向量 \mathbf{x} 从源域到目标域之间的变化情况. 当 $t=0$ 时, 表示投影到源域; 当 $t=1$ 时, $\Phi(1) = \mathbf{P}_{\mathcal{T}}$ 投影到目标域. 因

此, 当考虑所有 t 时, 特征投影之间的相似性度量对于单个子空间而言是不敏感的, 对于源域到目标域的参数变化具有一定的统计平均意义, 进而呈现鲁棒性特征.

对于输入 D 维特征向量 \mathbf{x}_i 和 \mathbf{x}_j , 特征投影为 \mathbf{z}_i 和 \mathbf{z}_j , 两点之间的相似性度量用内积来描述, 当 t 从 0 到 1 变化时, 所有的特征投影对应着无限维空间 \mathbf{z}^∞ 中两点 \mathbf{z}_i^∞ 、 \mathbf{z}_j^∞ . 如式 (10) 所示, 无穷维空间中两点之间的内积对应着特征投影沿测地线积分, 通过 GFK 计算 [16]. 其中 \mathbf{G} 是一个半正定对称矩阵, 如式 (11) 所示; \mathbf{A} 为对角矩阵, 对角元素如式 (12) 所示, 具体推导参见文献 [16].

$$\begin{aligned} \langle \mathbf{z}_i^\infty, \mathbf{z}_j^\infty \rangle &= \int_0^1 (\Phi(t)^T \mathbf{x}_i)^T (\Phi(t)^T \mathbf{x}_j) dt \\ &= \mathbf{x}_i^T \mathbf{G} \mathbf{x}_j \end{aligned} \quad (10)$$

$$\mathbf{G} = [\mathbf{P}_{\mathcal{S}} \mathbf{U}_1 \quad \mathbf{R}_{\mathcal{S}} \mathbf{U}_2] \begin{bmatrix} \mathbf{A}_1 & \mathbf{A}_2 \\ \mathbf{A}_2 & \mathbf{A}_3 \end{bmatrix} \begin{bmatrix} \mathbf{P}_{\mathcal{S}} \mathbf{U}_1 \\ \mathbf{R}_{\mathcal{S}} \mathbf{U}_2 \end{bmatrix} \quad (11)$$

$$\begin{aligned} \lambda_{1i} &= 1 + \frac{\sin(2\theta_i)}{2\theta_i} \\ \lambda_{2i} &= \frac{\cos(2\theta_i) - 1}{2\theta_i} \\ \lambda_{3i} &= 1 - \frac{\sin(2\theta_i)}{2\theta_i} \end{aligned} \quad (12)$$

3 基于测地线流式核的雷达目标 HRRP 鲁棒识别方法

本文主要研究小样本情况下信噪比失配的 HRRP 目标识别问题. 利用 PCA 降维的格拉斯曼流形子空间表示, 可以有效弥补数据量不足; 通过 GFK 技术, 提取平均意义上的鲁棒性特征, 降低信噪比变化的影响, 由此提出一种基于 GFK 的雷达目标 HRRP 鲁棒识别方法.

首先, 完成数据预处理. 由于 PCA 降维需要计算协方差矩阵和尽量保留数据方差, 因此对数据集去中心化到零均值, 即每个输入向量沿维度求和为零.

随后, 确定最优格拉斯曼流形维度. 由于式 (6) 中等式条件过于苛刻, 在小样本条件下不一定存在解, 因此对于式 (6) 在小样本条件下进行改进, 用不等式来逼近等式条件, 即采用式 (13) 所对应的 d^* , 其中门限值 $\text{Th} \in [0, 1]$ 应尽量接近于 1, 本文取为 0.995. 当样本数远小于特征维数时, $D(d)$ 的最大值可能会小于 Th , 此时取 $d^* = \max \{D(d)\}$. 由此, 可计算得到 d^* 维格拉斯曼流形矩阵 $\mathbf{P}_{\mathcal{S}}$ 和 $\mathbf{P}_{\mathcal{T}}$, 并利用式 (11) 计算核函数矩阵 \mathbf{G} .

$$d^* = \min \{D(d) \geq \text{Th}\} \quad (13)$$

最后, 基于核函数矩阵 \mathbf{G} , 可计算输入特征 \mathbf{x}_i 和 \mathbf{x}_j 在无限维空间中的距离 $D^\infty(\mathbf{x}_i, \mathbf{x}_j)$, 如式 (14) 所示. 以此为基础, 可以利用如 k 近邻 (k -Nearest Neighbor,

KNN),支持向量机(Support Vector Machine, SVM)等算法构建目标识别器.

$$\begin{aligned} D^\infty(\mathbf{x}_i, \mathbf{x}_j)^2 &= \|\mathbf{z}_i^\infty - \mathbf{z}_j^\infty\|^2 \\ &= \langle \mathbf{z}_i^\infty - \mathbf{z}_j^\infty, \mathbf{z}_i^\infty - \mathbf{z}_j^\infty \rangle \\ &= \mathbf{x}_i^\top \mathbf{G} \mathbf{x}_i + \mathbf{x}_j^\top \mathbf{G} \mathbf{x}_j - 2\mathbf{x}_i^\top \mathbf{G} \mathbf{x}_j \end{aligned} \quad (14)$$

还有另一种分类识别的思路. 由于 \mathbf{G} 是一个半正定对称矩阵, 对称矩阵的 SVD 为 $\mathbf{G} = \mathbf{S} \mathbf{A} \mathbf{S}^\top$, 其中 \mathbf{A} 中特征值大于等于零, 特征值取根号后可得 $\sqrt{\mathbf{A}}$, 求得 $\sqrt{\mathbf{G}} = \sqrt{\mathbf{A}} \mathbf{S}^\top$. 如式(15)所示, 通过 $\sqrt{\mathbf{G}} \mathbf{x}$ 可得到格拉斯曼流形中测地线积分对应的特征, 以此作为含噪样本 \mathbf{x} 在格拉斯曼流形上的无穷维投影, 进而提取得到更稳健的目标特征, 以 $\sqrt{\mathbf{G}} \mathbf{x}$ 作为原样本 \mathbf{x} 的鲁棒特征向量, 构建目标识别器.

$$\langle \mathbf{z}_i^\infty, \mathbf{z}_j^\infty \rangle = \mathbf{x}_i^\top \mathbf{G} \mathbf{x}_j = (\sqrt{\mathbf{G}} \mathbf{x}_i)^\top (\sqrt{\mathbf{G}} \mathbf{x}_j) \quad (15)$$

4 实验结果与分析

4.1 实验准备

三类飞机目标雷达 HRRP 归一化实测数据, 每类数据集有 26 000 个样本, 距离单元为 256, 其中雷达中心频率为 5 520 MHz, 信号带宽为 400 MHz 和飞机参数如表 1 所示, “安 26”为中型螺旋桨飞机, “奖状”为小型喷气式飞机, “雅克 42”为中型喷气式飞机.

对于小样本情况仿真, 采用随机抽样构造小样本数据集. 对于信噪比的改变, 在 HRRP 幅度数据上加入服从指定分布的加性噪声, 信噪比定义为 $10 \lg(P_{\text{signal}}/P_{\text{noise}})$, 其中 P_{signal} 和 P_{noise} 分别为信号和噪声平均功率. 实验均采用未添加噪声的训练集作为源域, 添加噪声的测试集作为目标域(后文有特别说明的除外). 由于测地线流式核中 PCA 需要保留样本方差, 数据预处理为中心化到零均值, 不改变方差. 采用蒙特卡洛方法重复实验, 每次实验随机抽取相同数量的样本, 取结果均值消除随机因素影响.

表 1 飞机参数 单位: m

飞机	机长	机高	机宽
安 26	23.80	9.83	29.20
奖状	14.40	4.57	15.90
雅克 42	36.38	9.83	34.88

4.2 算法识别性能分析

首先分析样本量变化、样本不均衡和不同类型噪声分布对目标识别算法性能的影响.

4.2.1 样本量变化

通过 GFK 计算样本距离, 目标识别器选择 KNN, k 值取 1, GFK+KNN 识别算法无需训练, 时效性好, 但由

于同时利用了训练集和测试集作为源域和目标域计算核函数, 因此训练集和测试集样本量均会影响识别性能.

在信噪比为 -3 dB 的瑞利噪声情况下, 实验结果如图 2 所示. 图 2(a) 测试集每类样本量为 500, 训练集每类样本量由 10 到 1 000, 蒙特卡洛方法重复 100 次, 在训练集每类样本量为 10 的情况下, 算法识别率在 80% 以上, 随着训练集每类样本量达到每类 100, 识别率提升到 90%. 同样测试集样本量也会影响性能, 图 2(b) 训练集每类样本量为每类 100, 测试集每类样本量由 2 到 200, 蒙特卡洛方法重复 100 次, 测试集识别率在极少样本情况仍在 85% 以上, 并随着测试样本量的增加而增加. 图 2(c) 训练集和测试集每类样本量由 10 到 500, 蒙特卡洛方法重复 100 次, 识别率也随着样本量增加而上升.


图 2 表明, 基于 GFK 的 HRRP 目标识别算法在少量样本情况下仍具有良好的识别性能, 当每类样本量从 1 000 降低为 100 时, 识别率变化仅下降了 5%, 并且样本量在每类 10 个时仍有 80% 以上的识别率, 这说明了子空间表示对于小样本的鲁棒性, 并且图 2(b) 中少量测试集样本即可达到较高的识别率, 保证了在实际情况中的实时性. 图 2(a) 与图 2(b) 相比, 图 2(a) 在训练集样本量减少的情况下, 相较于图 2(b) 的测试集样本量减少, 其识别率下降更为显著, 表明训练集样本量对于识别率的影响比测试集样本量大. 尽管训练集和测试集调换不会影响矩阵 \mathbf{G} 的计算, 但 KNN 依赖于训练集标注信息进行识别, 同时训练集为未添加噪声的原始信号, 更多的训练样本将有助于更好地提取不变特征, 提高识别性能.

4.2.2 样本不均衡


由于实际情况中各类样本数量并不相等, 训练集和测试集的不同类样本数量会影响识别性能. 表 2 的实验条件为瑞利噪声, 信噪比为 -3 dB, 蒙特卡洛方法重复 100 次, 假定各类重要性一致, 采用平均识别率作为评价指标. 实验结果显示, 训练集和测试集样本比例相差越大, 将导致识别率下降越多. 主要由于以下两方面引起, 一是不均衡的训练集比例变化会导致最优格拉斯曼流形维度变化更剧烈, 二是不均衡的训练集比例使得训练集样本空间没有包括测试集对应类的最小距离点, 使后端 KNN 识别率下降. 因此, 采用均衡的训练集样本比例对测试集样本不同类样本数量变化具有良好的鲁棒性.

4.2.3 不同类型噪声分布


实际情况中回波信号不可避免地存在干扰, 通常复数据的噪声会建模为高斯分布^[8, 21], 其幅度服从瑞利分布^[8, 9, 11]. 除噪声干扰外, 自然环境的雷达回波会



(a) 训练集样本量变化



(b) 测试集样本量变化



(c) 训练集和测试集样本量变化

图 2 样本量变化对 GFK+KNN 识别率影响

产生杂波干扰,杂波幅度统计模型更为复杂,包括高斯、瑞利、韦布尔、对数正态和伽玛分布等^[22].因此,需要考虑不同分布噪声对目标识别算法性能的影响.由于 GFK 并未预设分布类型,而是根据源域和目标域来提取数据的不变特征,因此对于不同分布具有良好的鲁棒性.实验结果如图 3 所示,训练集每类 100 个,测

试集每类 500 个,蒙特卡洛方法重复 100 次,信噪比大于 -3 dB 时,不同类型噪声对目标识别率的影响差异较小,这说明了 GFK 方法的统计平均效果对不同噪声分布在 -3 dB 之上是有效的.但随着信噪比下降,在 -3 dB 以后识别性能恶化明显低于 90%,此时 GFK+KNN 不能有效地处理被噪声所淹没的低信噪比样本.这种情况下,尽管 GFK 的统计平均效果降低了噪声干扰,但 KNN 所构建的分类器不具备抗噪声干扰能力.后续需要考虑噪声干扰的影响,同时设计特征提取和分类器方法.

此外,也可以不使用训练集和测试集作为源域和目标域计算矩阵 \mathbf{G} ,而是随机抽样另一批原始信号和指定信噪比信号作为源域和目标域.也即在计算矩阵 \mathbf{G} 时,源域和目标域分别为另一批随机抽取的原始信号和指定信噪比保持不变的样本集;在进行测试时,使用全新的训练集与测试集进行分类判别.如图 4 所示,训练集和测试集构造方法与图 3 实验相同,6 种不同信噪比条件下的目标域求得的矩阵 $\mathbf{G}_1, \dots, \mathbf{G}_6$,对于测试集识别率并没有明显影响.这说明了算法识别性能主要依赖于源域高信噪比数据中提取到的目标不变特征,而目标域中的噪声干扰并不会显著影响所提取特征的稳健性.同时也说明了格拉斯曼流形子空间表示的鲁棒性,并不依赖于特定的数据集,而是提取到了同类数据集的内在几何特征.

4.3 算法映射特征分析

进一步分析式 (15) 中 $\sqrt{\mathbf{G}}\mathbf{x}$ 映射后,在格拉斯曼流形空间中提取特征的鲁棒性.如图 5 所示,对图 5(a) 中原始信号添加了瑞利噪声后得到图 5(b) 的含噪信号,信噪比为 -10 dB,其中原始信号已经被噪声所淹没.图 5(c) 和 (d) 分别为原始信号和含噪信号经过 $\sqrt{\mathbf{G}}\mathbf{x}$ 映射得到结果图,对比两图可以发现, $\sqrt{\mathbf{G}}\mathbf{x}$ 映射能够从被噪声淹没的含噪信号中较好地恢复原始信号,这说明 GFK 方法具有良好的降噪能力.本文基于文献[23,24],使用如表 3 所示的雷达一维像描述特征,分析映射后特征的变化情况.表 3 中样本 $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_N]^T$ 为输入数据, N 为距离单元总数,由于映射后会出现负值,并且文献[24]采用幅度归一化数据计算特征,因此计算一维像描述特征时会对数据取绝对值并归一化.

训练集和测试集每类 100 个样本,计算得到映射矩阵 \mathbf{G} ,噪声分布假设为瑞利分布,蒙特卡罗重复 100 次实验.计算测试集中映射前后含噪信号与对应的原始信号之间一维像特征的相对误差 $\delta = |F - F_n| / F \times 100\%$,其中 F 为原始信号特征, F_n 为含噪信号特征.实验结果如图 6 所示,可以看出映射后能够显著降低特征误差,但在

低信噪比下,如-10 dB到-3 dB之间误差仍然较大.

表 2 样本不均衡情况下GFK+KNN识别率结果

测试集样本比 训练集样本比	50:500:500	100:500:500	200:500:500	500:500:500	1 000:500:500	2 500:500:500	识别率 变化最大值
10:100:100	94.87%	92.93%	89.50%	82.37%	74.30%	63.84%	31.03%
50:100:100	94.34%	93.42%	92.79%	89.97%	87.05%	83.52%	10.82%
100:100:100	92.74%	92.84%	92.48%	91.53%	90.38%	88.87%	3.97%
500:100:100	85.13%	86.25%	87.83%	90.55%	92.41%	94.39%	9.26%
50:500:500	96.78%	95.68%	93.41%	88.48%	83.37%	76.62%	20.16%
250:500:500	96.05%	95.79%	95.24%	94.01%	92.35%	90.12%	5.93%
500:500:500	94.90%	94.89%	95.07%	94.96%	94.32%	93.56%	1.51%
2 500:500:500	90.09%	90.70%	91.98%	93.96%	95.29%	96.54%	6.45%
100:1 000:1 000	97.32%	96.27%	94.55%	90.37%	86.11%	80.53%	16.79%
500:1 000:1 000	96.92%	96.59%	96.23%	95.01%	93.79%	91.83%	5.09%
1 000:1 000:1 000	95.89%	95.91%	96.02%	95.86%	95.31%	94.56%	1.46%
5 000:1 000:1 000	67.58%	71.00%	74.88%	81.00%	86.60%	92.66%	25.08%
识别率变化最大值	29.74%	25.59%	21.35%	14.86%	21.01%	32.70%	-




图 3 GFK+KNN在不同噪声类型的不同信噪比下的识别率结果

如图 7 所示,使用表 4 中不同识别方法对于原始输入特征 \mathbf{x} 和映射后特征 $\sqrt{G} \mathbf{x}$ 进行分析,其中全连接层方法和卷积神经网络方法的训练集和测试集样例分别如图 5(a) 和图 5(b) 所示,其余输入如图 5(c) 和图 5(d). 所用全连接层方法为三层结构. 卷积神经网络方法为文献[9]中以卷积层为架构的改进网络,并加入了批归一化层. 由于预处理方式为零均值去中心化,因此两者激活函数选择为 \tanh 函数,学习率为 $1e-4$,优化算




图 4 指定信噪比的GFK+KNN识别率结果

法为 Adam 算法. 图 7 表明,GFK 提取的特征在低信噪比下具有良好的识别效果,而更复杂的卷积神经网络方法在低信噪比下对噪声过拟合严重,效果反而不如简单的三层全连接层方法. 当然,-10 dB 信噪比下的鲁棒性识别有待进一步研究,试验表明当信噪比从-10 dB 下降到-20 dB 时,GFK 方法的识别率已经下降至 43%,此时信号强散射点已经完全被淹没在噪声之中,该方法已经无法提取到信号特征. 因此后续对于信噪比极

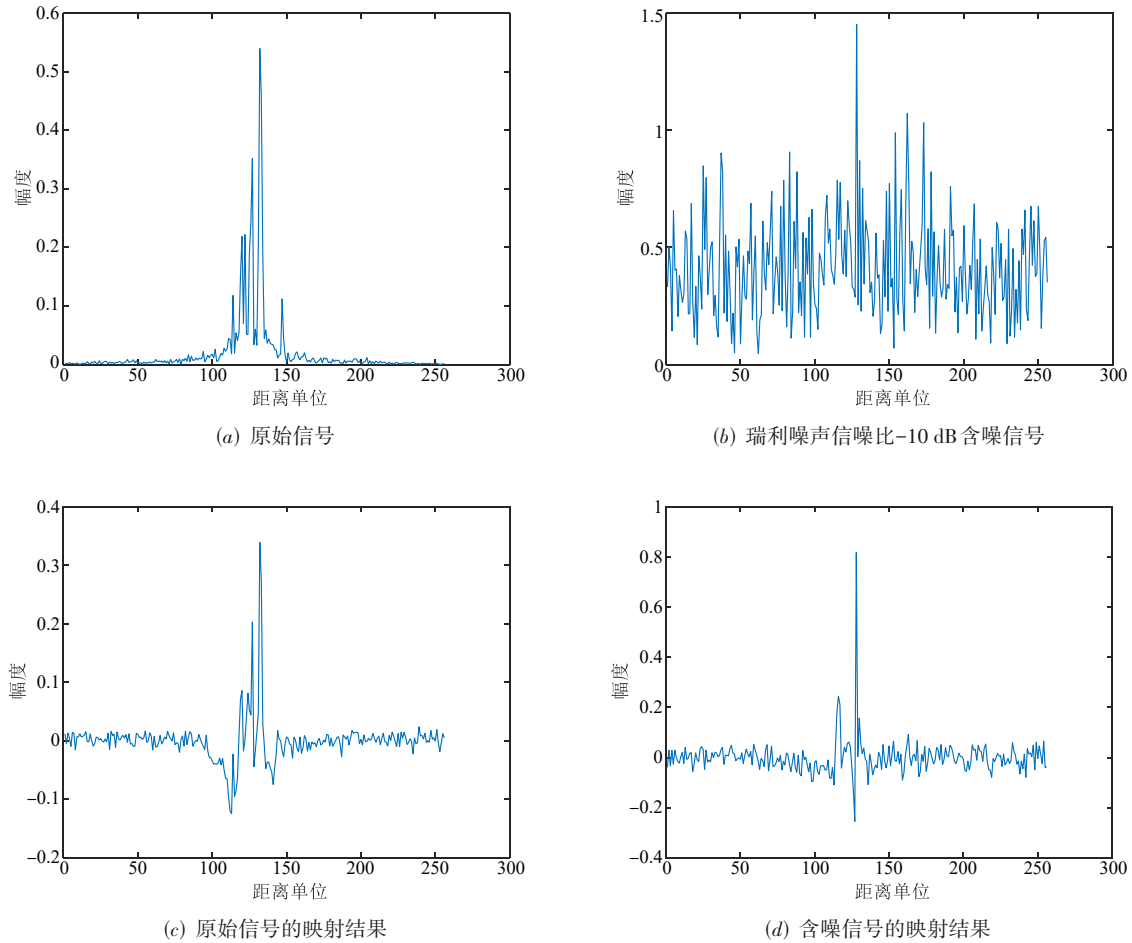


图 5 GFK 方法降噪效果示意图结果

表 3 雷达一维像特征

特征名称	公式	描述
整体熵分布	$-\sum_{i=1}^N x_i \ln(x_i)$	反映了目标散射中心分布情况,分布越集中其值越小
标准差	$20\lg\left(\sqrt{\frac{\sum_{i=1}^N (x_i - m)^2}{N-1}}\right), m = \frac{1}{N} \sum_{i=1}^N x_i$	反映了目标散射中心偏离均值的程度,其值越小说明散射中心分布越均匀
不规则度	$20\lg\left(\sum_{i=2}^{N-1} \left x_i - \frac{x_{i-1} + x_i + x_{i+1}}{3}\right \right)$	反映了相邻三个点上幅度的相对关系,一定程度上表征物体结构信息
径向能量	$10\lg\left(\sum_{i=2}^N x_i^2\right)$	反映了目标电磁波反射能力
对称度	$\left[\sum_{i=1}^{N/2} x_i \right] / \left[\sum_{j=N/2}^N x_j \right]$	反映了目标散射截面积分布的对称程度
二阶中心矩	$\left[\sum_{i=1}^N \left(\frac{i}{N} - n\right)^2 x_i\right] / \left[\sum_{i=1}^N x_i\right]^3,$ $n = \left[\sum_{i=1}^N \frac{i}{N} x_i\right] / \left[\sum_{i=1}^N x_i\right]$	中心矩特征具有平移、旋转以及尺度不变性,能够反映目标的形状信息

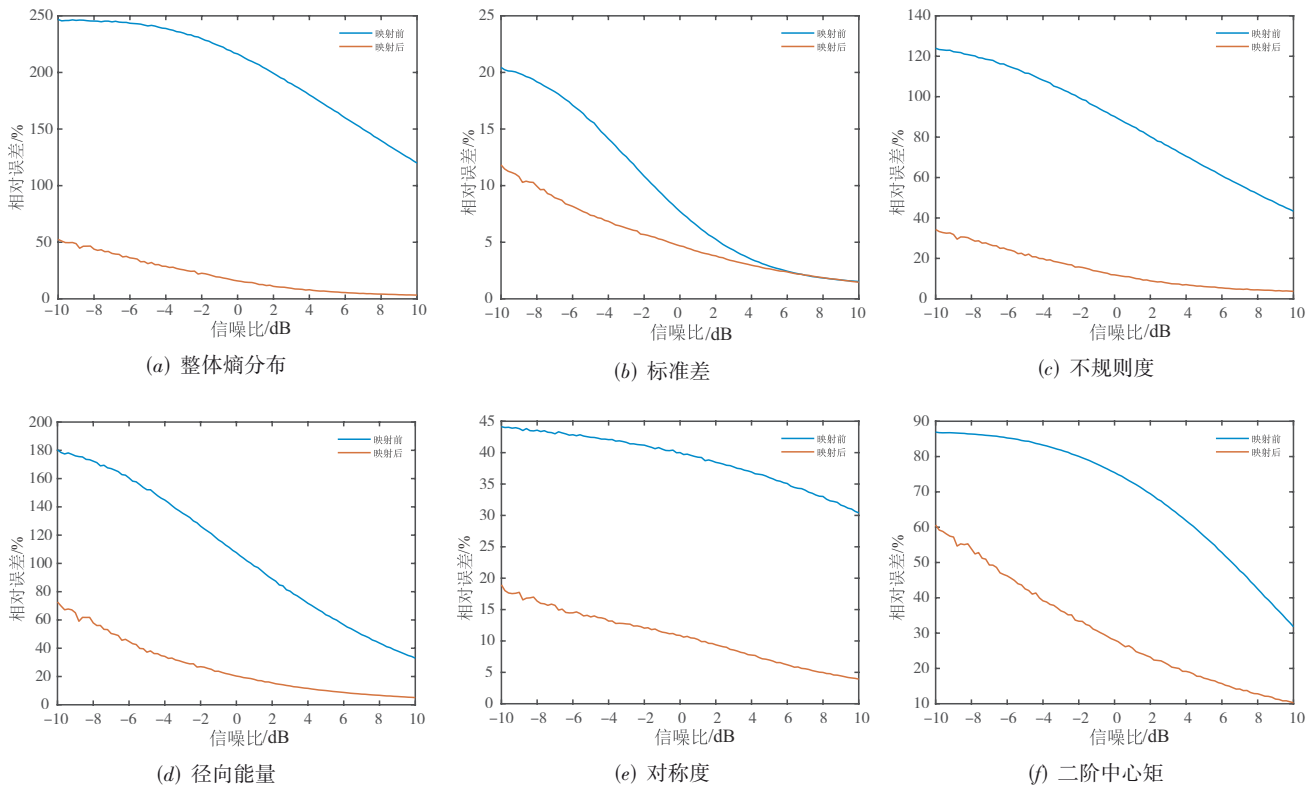


图 6 一维特征相对误差

表 4 不同识别方法

方法	介绍
GFK+KNN	对于映射后的特征 $\sqrt{G}x$, 采用最近邻算法依据式(14)计算的距离确定类别
KNN	对 HRRP 数据采用最近邻规则进行分类, 其中 $k=1$
GFK+全连接层	对于映射后的特征 $\sqrt{G}x$, 采用三层全连接层作为识别器. 三层全连接层输入节点数为 256, 中间节点数为 1 024 和 256, 输出节点数为 3, 第一层与第二层激活函数选择为 tanh 函数
全连接层	对于输入特征 x , 采用三层全连接层作为识别器. 全连接层结构不变
GFK+卷积神经网络	对于映射后的特征 $\sqrt{G}x$, 采用文献[9]的卷积神经网络作为识别器. 激活函数改为 tanh 函数, 并加入批归一化层加速训练
卷积神经网络	对于输入特征 x , 采用文献[9]的卷积神经网络作为识别器. 卷积神经网络结构不变

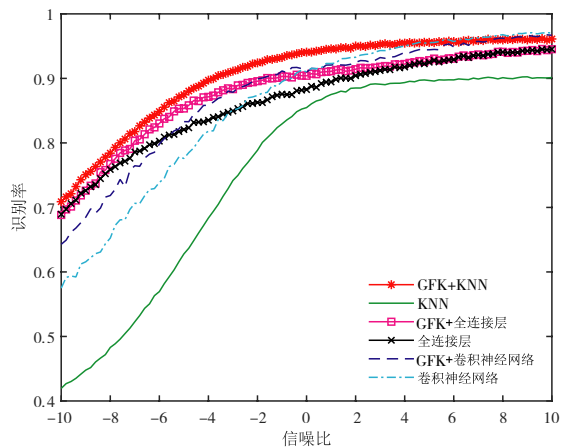


图 7 不同方法识别率结果图

低下, 噪声压制性干扰的鲁棒性识别算法还有待进一步研究.

5 结束语

本文提出了一种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, 通过 PCA 降维得到的子空间表示降低了对于样本量的需求, 通过测地线流式核得到了鲁棒的几何特征. 该方法具有清晰的数学物理内涵和解析表达式, 并且无需对噪声分布的先验假设构造训练集, 大量实验验证了该方法的鲁棒性. 本文方法还可以作为降噪预处理手段, 后端与多种识别方法相结合, 扩展应用性强. 未来将进一步研究格拉斯曼流形曲面性质, 结合深度学习拟合能力研究微弱目标识别和多种干扰条件下的目标识别.

参考文献

- [1] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4): 395-411.
WANG J, ZHENG T, LEI P, et al. Study on deep learning in radar[J]. Journal of Radars, 2018, 7(4): 395-411. (in Chinese)
- [2] 韩磊, 姚璐. HRRP 自动目标识别方法综述[J]. 北京理工大学学报, 2020, 40(4): 351-361, 381.
HAN L, YAO L. A review of methods for HRRP target automatic recognition[J]. Transactions of Beijing Institute of Technology, 2020, 40(4): 351-361, 381. (in Chinese)
- [3] YANG Z T, DENG J, NALLANATHAN A. Moving target recognition based on transfer learning and three-dimensional over-complete dictionary[J]. IEEE Sensors Journal, 2016, 16(14): 5671-5678.
- [4] 杨予昊, 孙晶明, 虞盛康. 基于卷积神经网络迁移学习的飞机目标识别[J]. 现代雷达, 2019, 41(12): 35-39.
YANG Y H, SUN J M, YU S K. Aircraft target recognition based on convolutional neural network with transfer learning[J]. Modern Radar, 2019, 41(12): 35-39. (in Chinese)
- [5] 司进修. 基于深度学习的雷达一维距离像目标识别方法研究与实现[D]. 成都: 电子科技大学, 2019.
SI J X. Research and Implementation of Radar One-Dimensional Range Profile Target Recognition Method Based on Deep Learning[D]. Chengdu: University of Electronic Science and Technology of China, 2019. (in Chinese)
- [6] WEN Y, SHI L C, YU X, et al. HRRP target recognition with deep transfer learning[J]. IEEE Access, 8: 57859-57867.
- [7] SHI L C, LIANG Z H, WEN Y, et al. One-shot HRRP generation for radar target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [8] 王鹏辉. 基于统计建模的雷达高分辨距离像目标识别方法研究[D]. 西安: 西安电子科技大学, 2012.
WANG P H. Study of Radar High Resolution Range Profile Target Recognition Based on Statistical Modeling[D]. Xi'an: Xidian University, 2012. (in Chinese)
- [9] 李玮杰, 杨威, 黎湘, 等. 一种噪声环境下的雷达目标高分辨率距离像鲁棒识别方法[J]. 雷达学报, 2020, 9(4): 622-631.
LI W J, YANG W, LI X, et al. Robust high resolution range profile recognition method for radar targets in noisy environments[J]. Journal of Radars, 2020, 9(4): 622-631. (in Chinese)
- [10] WANG G S, WANG W Y, LEI Z Y, et al. A method to improve the generalization ability of HRRP recognition model-deep adaptation networks[C]//2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference. Piscataway: IEEE, 2020: 799-803.
- [11] 王国帅, 汪文英, 魏耀, 等. 基于混合核深度适配网络的HRRP 目标识别[J]. 雷达科学与技术, 2020, 18(6): 618-624.
WANG G S, WANG W Y, WEI Y, et al. HRRP target recognition based on mixed kernel deep adaptation networks[J]. Radar Science and Technology, 2020, 18(6): 618-624. (in Chinese)
- [12] 李玮杰, 杨威, 刘永祥, 等. 雷达图像深度学习模型的可解释性研究与探索[J]. 中国科学: 信息科学, 2022, 52(6): 1114-1134.
LI W J, YANG W, LIU Y X, et al. Research and exploration on the interpretability of deep learning model in radar image[J]. Scientia Sinica (Informationis), 2022, 52(6): 1114-1134. (in Chinese)
- [13] DU L, LIU H, BAO Z, et al. Radar automatic target recognition using complex high-resolution range profiles[J]. IET Radar, Sonar & Navigation, 2007, 1(1): 18-26.
- [14] 杜兰. 雷达高分辨距离像目标识别方法研究[D]. 西安: 西安电子科技大学, 2007.
DU L. Study on Radar HRRP Target Recognition[D]. Xi'an: Xidian University, 2007. (in Chinese)
- [15] HAMM J, LEE D D. Grassmann discriminant analysis: A unifying view on subspace-based learning[C]//Proceedings of the 25th International Conference On Machine learning. New York: ACM, 2008: 376-383.
- [16] GONG B Q, SHI Y, SHA F, et al. Geodesic flow kernel for unsupervised domain adaptation[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2012: 2066-2073.
- [17] ABSIL P A, MAHONY R, SEPULCHRE R. Riemannian geometry of Grassmann manifolds with a view on algorithmic computation[J]. Acta Applicandae Mathematica, 2004, 80(2): 199-220.
- [18] WONG Y C. Differential geometry of Grassmann manifolds[J]. Proceedings of the National Academy of Sciences of the United States of America, 1967, 57(3): 589-594.
- [19] GOLUB G H, VAN LOAN C F. Matrix Computations [M]. Baltimore: Johns Hopkins University Press, 2013.
- [20] EDELMAN A, ARIAS T A, SMITH S T. The geometry of algorithms with orthogonality constraints[J]. SIAM Journal on Matrix Analysis and Applications, 1998, 20(2): 303-353.

- [21] 李龙, 刘峥. 采用多特征联合学习的噪声稳健 HRRP 识别方法[J]. 西安电子科技大学学报, 2018, 45(4): 57-62.
LI L, LIU Z. Noise-robust multi-feature joint learning HRRP recognition method[J]. Journal of Xidian University, 2018, 45(4): 57-62. (in Chinese)
- [22] 张良, 杨威, 李玮杰, 等. 基于复数卷积-残差网络的雷达杂波幅度统计模型分类[J]. 系统工程与电子技术, 2021, 43(11): 3086-3097.
ZHANG L, YANG W, LI W J, et al. Classification of radar clutter amplitude statistical model based on complex-valued convolutional-ResNet[J]. Systems Engineering and Electronics, 2021, 43(11): 3086-3097. (in Chinese)
- [23] 庄钊文, 王雪松, 黎湘. 雷达目标识别[M]. 北京: 高等教育出版社, 2015.
- [24] 韩磊, 周帅. 基于FLAKNN的雷达一维距离像目标识别[J]. 北京理工大学学报, 2021, 41(6): 611-618.
HAN L, ZHOU S. Radar range profile target recognition based on FLAKNN[J]. Transactions of Beijing Institute of Technology, 2021, 41(6): 611-618. (in Chinese)
- [25] DU L, WANG P H, LIU H W, et al. Bayesian spatiotemporal multitask learning for radar HRRP target recognition[J]. IEEE Transactions on Signal Processing, 2011, 59(7): 3182-3196.



黎湘 男, 1967年出生, 湖南浏阳人. 国防科技大学教授, 研究方向为目标探测识别与雷达成像等. 中国电子学会会员编号: E190005517S.

作者简介



杨威 男, 1985年出生, 江西丰城人. 国防科技大学副教授. 研究方向包括认知雷达目标探测与识别、雷达目标跟踪.
E-mail: yw850716@sina.com



李玮杰(通讯作者) 男, 1998年出生, 湖南株洲人. 本科毕业西安交通大学, 现为国防科技大学直博生. 研究方向为雷达目标识别, 机器学习.
E-mail: lwj2150508321@sina.cn



刘永祥 男, 1976年出生, 河北唐山人. 国防科技大学教授, 博士生导师, 研究方向为目标微动特性分析与识别. 中国电子学会会员编号: E190002703S.
E-mail: lyx_bible@sina.com