

基于联合动态稀疏表示的开集距离像目标识别方法

刘盛启^{*①} 张会强^① 滕书华^② 瞿爽^① 吴中杰^①

^①(国防科技大学自动目标识别重点实验室 长沙 410073)

^②(湖南第一师范学院电子信息学院 长沙 410205)

摘要: 针对开集条件下多视高分辨距离像(HRRP)目标识别问题,提出了一种基于联合动态稀疏表示(JDSR)的开集识别方法。该方法利用JDSR求解多视HRRP在过完备字典上的重构误差,采用极值理论(EVT)对匹配和非匹配类别的重构误差拖尾进行建模,将开集识别问题转化为假设检验问题求解。识别时利用重构误差确定候选类,根据尾部分布的置信度获得匹配类与非匹配类得分,并将两者的加权和作为类别判据最终确定库外目标或候选类。该方法能够有效利用多视观测来自相同目标的先验信息提高开集条件下的HRRP识别性能,并且对多视数据不同的获取场景具有良好的适应性。利用从MSTAR反演生成的HRRP数据对算法进行了测试,结果表明所提方法的性能优于主流开集识别方法。

关键词: 开集识别; 联合动态稀疏表示; 极值理论; 高分辨距离像

中图分类号: TN959.1+7

文献标识码: A

文章编号: 1009-5896(2023)11-4101-09

DOI: 10.11999/JEIT221284

Open-set HRRP Target Recognition Method Based on Joint Dynamic Sparse Representation

LIU Shengqi^① ZHANG Huiqiang^① TENG Shuhua^②

QU Shuang^① WU Zhongjie^①

^①(National Key Laboratory of Science and Technology on Automatic Target Recognition,
National University of Defense Technology, Changsha 410073, China)

^②(College of Electronic Information, Hunan First Normal University, Changsha 410205, China)

Abstract: Focusing on the issue of multi-view High-Resolution Range Profile (HRRP) target recognition in an open set, a novel method based on Joint Dynamic Sparse Representation (JDSR) is presented. First, JDSR is used to solve the reconstruction error of multi-view HRRP on the over completed dictionary. The reconstruction error trails of matched and unmatched categories are modeled using Extreme Value Theory (EVT), and subsequently, the open-set recognition problem is transformed into a hypothesis test problem. The reconstruction error is used to determine candidate classes during the identification phase. The matched and nonmatched class scores are obtained based on the confidence level of the tail distribution, and their weighted sum is used to decide whether the inputs are from nonlibrary categories or candidate classes. The input HRRPs are obtained from the same target and can be used as useful information to improve recognition performance. The proposed method can effectively use such prior information for performance enhancement under the open-set condition. Moreover, performance can remain robust under multiview data acquisition scenarios. The HRRP data generated from MSTAR chips are used for the identification experiments, and the results reveal that the proposed method performs considerably better than some state-of-the-art methods.

Key words: Open-Set Recognition (OSR); Joint Dynamic Sparse Representation (JDSR); Extreme value theory; High-Resolution Range Profile (HRRP)

收稿日期: 2022-10-10; 改回日期: 2023-10-12; 网络出版: 2023-10-18

*通信作者: 刘盛启 SQLiu@nudt.edu.cn

基金项目: 国家自然科学基金(62001486, 62201587), 湖南省自然科学基金(2023JJ0185), 湖南省教育厅科学研究重点项目(22A0640)

Foundation Items: The National Natural Science Foundation of China (62001486, 62201587), Hunan Provincial Natural Science Foundation Project (2023JJ0185), The Key Scientific Research Project of Hunan Provincial Department of Education (22A0640)

1 引言

高分辨距离像(High Range Resolution Profile, HRRP)是宽带雷达获取的目标回波在不同距离单元上的分布,反映了一定视角下雷达目标的散射特性,包含了目标的重要结构信息^[1],对于目标识别分类十分有价值。

目前,有关HRRP的雷达目标识别已经产生了丰富的研究成果^[2-5],但主要集中在闭集假设条件下取得,即假定测试样本来自训练集包含的目标类别,然后设计一定的分类准则将测试样本判断为具有最佳匹配的目标类别。然而实际应用中往往会面临非合作目标,待识别样本很可能来自训练集以外的未知类别(开集情况),这时传统方法会将待识别样本判断为训练集内置信度最高的目标类别,得到错误的结果。针对这个问题,传统方法有以下改进思路:一是利用单分类器判断测试样本是否来自库外目标^[3];二是在闭集分类器的基础上增加拒判功能^[4,5]。然而单分类器将库内目标当成一类忽略了目标间的辨别信息,会损害目标的分辨性能;而由于库外目标训练样本缺失,第二种思路的拒判门限很难设定。提高拒判性能需要设置较高的门限,但是会明显增加对库内目标的错误拒识概率。

针对开放环境下的目标识别问题,Scheirer等人^[6]定义了开集识别(Open Set Recognition, OSR)问题,建立了OSR理论框架。在此框架下,学者相继提出了一系列算法,可大致分为以下几类:(1)基于支持向量机(SVM)的识别方法,如1-vs-set^[6],W-SVM^[7],PI-SVM^[8]算法等;(2)基于稀疏表示(SR)的识别方法,如SR-OSR算法^[9];(3)基于距离准则的识别方法,如Nearest Non-Outlier^[10]、反向k-最近邻分类器^[11]等;(4)基于深度神经网络(DNN)的识别方法,如深度开放分类器^[12]、类别条件编码器^[13]、KLD-PRA联合判别器^[14]等;(5)基于边缘分布的识别方法,如极值机算法^[15]。在开集条件下OSR方法取得了较好的识别效果,但相关成果主要集中在计算机视觉领域,雷达目标识别特别是基于HRRP的目标识别应用还鲜有报道。

针对多站从多视角获得同一目标多个观测数据的应用场景,多观测数据可能来自较小的角度范围,也有可能具有较大的角度间隔。根据雷达目标特性可知,多观测间可能具有很强的相关性,也有可能具有很大的差异。为了适应多视数据从多观测角度获取的不同应用场景,并且充分利用多视HRRP来自相同目标的先验信息,本文在OSR框架下,基于极值理论(Extreme Value Theory, EVT)将联合动态稀疏表示(Joint Dynamic Sparse Representation,

JDSR)方法应用于开集条件下的多视HRRP目标识别。利用EVT对训练阶段获得的重构误差拖尾进行拟合,得到各训练类别的极值分布,将测试样本尾部分布置信度作为匹配类及非匹配类得分,对两得分加权求和获得最终判据值进而判决目标类别。基于MSTAR反演生成的HRRP数据集的实验结果显示了算法的优越性能。

2 理论背景

2.1 联合动态稀疏表示(JDSR)

JDSR是对于稀疏表示(SR)的推广。在信号重构时JDSR施加块稀疏约束,在相同的块上共享同一种稀疏模式,而在原子级上则允许存在差异。因此,JDSR能够利用具有某些特定条件的块(如来自相同类别的字典原子)进行信号重构,并且可以灵活选择块内原子进行精确的信号重构。

设多观测信号为 $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J] \in \mathbb{R}^{M \times J}$ (J 为观测数目),JDSR通过估计信号 \mathbf{Y} 在字典 \mathbf{D} 上的上稀疏表示系数 $\boldsymbol{\alpha}$ 对 \mathbf{Y} 进行近似,其中 $\boldsymbol{\alpha} = [\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_J] \in \mathbb{R}^{N \times J}$ 表示行稀疏矩阵。上述过程利用非等式约束可表示为

$$\hat{\boldsymbol{\alpha}} = \min_{\boldsymbol{\alpha}} \|\mathbf{Y} - \mathbf{D}\boldsymbol{\alpha}\|_2, \quad \text{s.t.} \quad \|\boldsymbol{\alpha}\|_G \leq K \quad (1)$$

其中, $\|\boldsymbol{\alpha}\|_G = \left\| \left[\|\boldsymbol{\alpha}_{g_1}\|_2, \|\boldsymbol{\alpha}_{g_2}\|_2, \dots \right] \right\|_0$ 表示块稀疏约束, $\boldsymbol{\alpha}_{g_n} = [\boldsymbol{\alpha}(g_n(1), 1), \boldsymbol{\alpha}(g_n(2), 2), \dots]$ 表示第 n 个动态活动集(Dynamic Active Set, DAS)由 \mathbf{g}_n 指示的矩阵元素组成的系数向量, \mathbf{g}_n 由 $\boldsymbol{\alpha}$ 中来自同一块系数元素对应的行坐标组成的集合,即 $\mathbf{g}_n(m)$ 指 $\boldsymbol{\alpha}$ 第 m 列的第 $\mathbf{g}_n(m)$ 个元素。

2.2 极值理论

假设独立同分布随机变量序列 X_1, X_2, \dots, X_n ,设 $X_{n,n}$ 为此序列最大值。Fisher-Tippett定理^[16]指出,如果存在常数 $a_n > 0, b_n$,使得 $(X_{n,n} - b_n)/a_n$ 的渐进分布是非退化的,即

$$P\left(\frac{X_{n,n} - b_n}{a_n} \leq x\right) \rightarrow G(x), n \rightarrow \infty \quad (2)$$

那么, G 必属于Frechet-Pareto型、Gumbel型或Weibull型分布。

上述定理可通过广义极值分布(General Extreme Value distribution, GEV)表示:

$$G_\gamma: x \mapsto \exp\left(-\frac{1 + \gamma x}{\gamma}\right), \gamma \in \mathbb{R}, 1 + \gamma x > 0 \quad (3)$$

其中, γ 为极值指数,取决于原始数据的分布规律。

γ 可采用POT(Peaks-Over-Threshold)方法来估计,该方法依赖于Pickands-Balkema-de Haan定理^[17],即

对充分大的门限值 t , 超额值的分布 $\bar{F}_t(x) = P(X - t > x | X > t)$ 近似服从广义帕累托分布(General Pareto Distribution, GPD):

$$G_{\gamma,t,\sigma}(x) = \begin{cases} \left(1 + \gamma \frac{x-t}{\sigma}\right)^{-\frac{1}{\gamma}}, & \gamma > 0, x > t \\ \exp\left(-\frac{x-t}{\sigma}\right), & \gamma = 0, x > t \\ \left(1 + \gamma \frac{x-t}{\sigma}\right)^{-\frac{1}{\gamma}}, & \gamma < 0, t < x < t - \frac{\sigma}{\gamma} \end{cases} \quad (4)$$

通过选取门限值 t , 利用超过 t 的观测值来估计广义帕累托分布。记溢额函数 $Y_j = X_j - t$, 其中 $X_j > t$, $j = 1, 2, \dots, N_t$ 表示第 j 个溢出值在 X 序列对应的下标, $N_t = \sum_{i=1}^n I(X_i > t)$, $I(\cdot)$ 为指示函数。其对应的对数极大似然函数为

$$\lg L(\sigma, \gamma) = -N_t \lg \sigma - \left(\frac{1}{\gamma} + 1\right) \sum_{i=1}^{N_t} \lg \left(1 + \gamma \frac{Y_j}{\sigma}\right) \quad (5)$$

其中, $1 + \gamma \frac{Y_i}{\sigma} > 0, i = 1, 2, \dots, N_t$ 。若 $\gamma = 0$, 则似然函数为

$$\lg L(\sigma, \gamma) = -N_t \lg \sigma - \frac{1}{\sigma} \sum_{i=1}^{N_t} Y_j \quad (6)$$

根据似然函数即可求得各参数估计 $\hat{\sigma}, \hat{\gamma}$ 。

3 基于JDSR的开集HRRP识别方法

实际应用中, 多站雷达获取的目标观测往往对应目标不同的姿态角。根据雷达目标特性可知, 随着角度间隔差异的增大, 目标回波会依次出现距离单元幅度起伏、散射中心越距离单元走动及散射中心模型变化^[18], 多观测间的相关性也逐渐由强转弱。因此, 分类器需要在充分利用多视观测信息的同时, 对多视观测来自不同的角度间隔的应用场景均具有较好的鲁棒性。并且实际应用场景面向的对象往往种类繁多, 观测数据可能来自库外未知的目标类别, 采用传统的识别模型无法实现精准的判决, 需要研究开集条件下的识别问题。

开集条件下的识别(OSR)可以描述为开集风险函数最小化问题

$$\arg \min_f R_H(f) + \lambda R_C(f(\chi)) \quad (7)$$

其中, f 表示可度量的识别函数, R_H 和 R_C 分别表示相应的开放空间风险和经验风险, λ 是正则化常数, 用于权衡开放空间风险和经验风险。

识别函数 f 应满足以下条件: 一是识别函数输出值应是有界的; 二是函数在远离库内目标样本的

开放空间快速单调递减。JDSR利用最小重构误差来对类别进行判决, 测试样本对于对应类别的重构误差远低于其他类别的重构误差, 满足式(7)中识别函数 f 的要求, 故JDSR算法可以作为开集多视HRRP分类的识别函数。

对输入的多视观测样本 \mathbf{Y} , 在过完备字典 \mathbf{D} 上的联合稀疏表示可建模为式(1)优化问题, 通过求解稀疏系数 α 使得对原信号的描述误差最小。本文采用JDSR算法对式(1)求解, 得到稀疏系数 $\hat{\alpha}$ 后, 利用最小重构误差准则判决目标类别

$$\hat{c} = \arg \min_{c \in \{1, 2, \dots, C\}} \|\mathbf{Y} - \mathbf{D}\sigma_c(\hat{\alpha})\|_2^2 \quad (8)$$

其中, $\sigma_c(\hat{\alpha})$ 表示保留 $\hat{\alpha}$ 中对应于第 c 类的系数, 并将其他元素置零。

开放集条件下, 需确保式(7)的风险函数最小化及识别函数要求, 本文引入极值理论对JDSR算法输出的重构误差拖尾进行描述。由Pickands-Balkema-de Haan定理可知, 对于超过充分大的门限值的重构误差, 其超额值近似服从GPD。设训练阶段第 c 类目标重构误差数量为 N_c , 将重构误差从大到小排序并选取前 $N_t = N_c \cdot \rho$ 个重构误差作为拖尾($0 < \rho < 1$ 表示尾部大小参数), 第 $N_t + 1$ 个重构误差作为门限值 t 。对超过 t 的拖尾采用GPD进行拟合并依据式(5)、式(6)估计极值参数, 参数拟合过程如算法1所示。

对测试样本, 首先根据式(8)选取最小重构误差对应类别作为候选类, 然后依据训练阶段拟合结果对待识样本重构误差作Kolmogorov Smirnov统计检验^[19], 获取其属于对应的拖尾拟合分布的置信度, 从而判断其属于候选类或是库外目标。通过上述步骤, 开集识别问题被转化为式(9)的假设检验问题

$$\left. \begin{aligned} H_0 : G(r_c) \leq \delta_g \\ H_1 : G(r_c) > \delta_g \end{aligned} \right\} \quad (9)$$

其中, H_0 表示测试数据属于候选类, H_1 表示测试数据属于库外目标, $G(r_c)$ 是对应于重构误差 r_c 尾部的拟合, δ_g 是拒绝阈值。

综上, 基于JDSR的多视HRRP开集识别方法如图1所示。具体可分为如下步骤:

训练阶段:

步骤1 对训练样本作数据预处理, 提取特征信息并构建过完备字典;

步骤2 利用JDSR计算训练样本在过完备字典上的重构误差, 并分别计算每一类的匹配重构误差, 及非匹配重构误差之和;

步骤3 选定尾部参数并利用极值理论分别对

算法1 重构误差拟合及参数估计流程

1. 输入: 训练阶段重构误差 $\mathbf{R} = [R_1, R_2, \dots, R_c]$
2. 匹配类重构误差 $\mathbf{R}_c^m = \mathbf{R}(:, c)$, 非匹配类重构误差: $\mathbf{R}_c^{nm} = \sum_{i:i \neq c} R(:, i)$
3. 对重构误差排序: $\mathbf{R}_c = [r_{c1}, r_{c2}, \dots, r_{cN_c}]^T, r_{c1} \leq r_{c2} \leq \dots \leq r_{cN_c}$
4. 选取匹配类重构误差右拖尾 $\rho_c^m = [r_{c(N_c\rho)}^m, r_{c(N_c\rho+1)}^m, \dots, r_{cN_c}^m]$, 非匹配类重构误差左拖尾 $\rho_c^{nm} = [r_{c1}^{nm}, r_{c2}^{nm}, \dots, r_{c(N_c\rho)}^{nm}]$
5. 选取匹配类门限值 $t_c^m = r_{c(N_c\rho-1)}^m$, 非匹配类门限值 $t_c^{nm} = r_{c(N_c\rho+1)}^{nm}$
6. 匹配类溢额值 $\mathbf{X}_c^m = [r_{c(N_c\rho)}^m - t_c^m, r_{c(N_c\rho+1)}^m - t_c^m, \dots, r_{cN_c}^m - t_c^m]$, 非匹配类溢额值 $\mathbf{X}_c^{nm} = -[r_{c1}^{nm} - t_c^{nm}, r_{c2}^{nm} - t_c^{nm}, \dots, r_{c(N_c\rho)}^{nm} - t_c^{nm}]$
7. 估计极值参数 $\lg L(\sigma^m, \gamma^m) = -N_c \lg \sigma - \left(\frac{1}{\gamma} + 1\right) \sum_{i=1}^{N_c} \lg \left(1 + \gamma \frac{X_c^m}{\sigma}\right)$,
 $\lg L(\sigma^{nm}, \gamma^{nm}) = -N_c \lg \sigma - \left(\frac{1}{\gamma} + 1\right) \sum_{i=1}^{N_c} \lg \left(1 + \gamma \frac{X_c^{nm}}{\sigma}\right)$
8. 输出参数 $\hat{\sigma}^m, \hat{\gamma}^m, \hat{\sigma}^{nm}, \hat{\gamma}^{nm}$

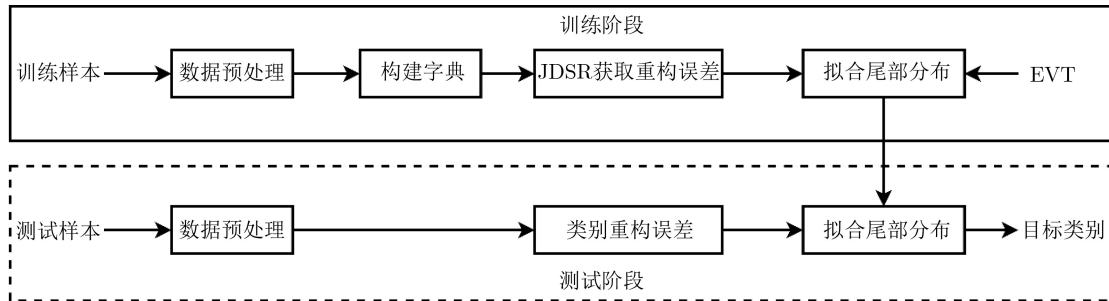


图1 JDSR-OSR算法流程图

匹配重构误差及非匹配重构误差之和进行拟合，得到相应的极值参数估计。

测试阶段:

步骤1 利用JDSR计算测试样本在过完备字典上的重构误差，选定误差最小的对应类别作为候选类;

步骤2 根据训练阶段得到的候选类对应的极值参数拟合GPD，获取对应训练阶段尾部分布的置信度作为判决得分，通过选定判决阈值判断测试样本类别。

3.1 训练阶段

在训练阶段，我们需要获取重构误差拟合GPD分布，从而根据极大似然估计来求解极值分布参数，JDSR-OSR训练过程如算法2所示。假设训练阶段获得了C类目标的训练数据，为了获得重构误差，我们对训练样本 $\mathbf{Y}_{tr} = [\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_C]$ 作预处理，首先构建过完备字典，字典构建方法可以采用人工构建法、元学习方法等^[20]。构建各类别子字典 $\mathbf{D}_i \in \mathbb{R}^{N_i \times T}, i = 1, 2, \dots, C$ 并将其整合为过完备字典 $\mathbf{D}, \mathbf{D} = [\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_C]$ 。对获取的多视数据 $\mathbf{y} = [y_{ci}, y_{c(i+1)}, \dots, y_{c(i+n)}]$ (n 为多视数目)，获取其对应于训练标签集 $\mathbf{L}_{tr} = [L_1, L_2, \dots, L_C]$ 的多视标签

算法2 JDSR-OSR训练算法

- 1 输入: 训练样本 $\mathbf{Y}_{tr} = [\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_C]$, 标签集 $\mathbf{L}_{tr} = [L_1, L_2, \dots, L_C]$, 字典矩阵 \mathbf{D} , 稀疏度 K , 多视数目 n , 尾部大小 ρ
- 2 训练样本划分为多视数据 $\mathbf{Y}_{11} = [\mathbf{y}_{11}, \mathbf{y}_{12}, \dots, \mathbf{y}_{1(1+n)}]$,
 $\mathbf{L}_{11} = [l_{11}, l_{12}, \dots, l_{1(1+n)}], \dots,$
 $\mathbf{Y}_{ci} = [\mathbf{y}_{ci}, \mathbf{y}_{c(i+1)}, \dots, \mathbf{y}_{c(i+n)}],$
 $\mathbf{L}_{ci} = [l_{ci}, l_{c(i+1)}, \dots, l_{c(i+n)}]$
- 3 计算重构误差 $\mathbf{R} \leftarrow \text{JDSR}(\mathbf{Y}, l, \mathbf{D}, K)$
- 4 匹配类重构误差: $\mathbf{R}_c^m = \mathbf{R}(:, c)$; 非匹配类重构误差:
 $\mathbf{R}_c^{nm} = \sum_{i:i \neq c} \mathbf{R}(:, i)$
- 5 拟合尾部极值参数: $\text{GPDfit}(\mathbf{R}_c^m, \rho) \rightarrow \hat{\sigma}_c^m, \hat{\gamma}_c^m$
 $\text{GPDfit}(-\mathbf{R}_c^{nm}, \rho) \rightarrow \hat{\sigma}_c^{nm}, \hat{\gamma}_c^{nm}$
- 6 输出极值参数 $\hat{\sigma}_c^m, \hat{\gamma}_c^m, \hat{\sigma}_c^{nm}, \hat{\gamma}_c^{nm}$

$\mathbf{l} = [l_{ci}, l_{c(i+1)}, \dots, l_{c(i+n)}]$, 利用JDSR算法计算稀疏系数并获得重构误差。考虑到可以利用非匹配类信息强化匹配类信息，因此分别对每类目标获取其匹配重构误差 $\mathbf{R}_c^m = \mathbf{R}(:, c)$ 及非匹配重构误差之和 $\mathbf{R}_c^{nm} = \sum_{i:i \neq c} \mathbf{R}(:, i)$ ，选取尾部大小 ρ 得到对应门限值 t_c^m, t_c^{nm} 。由于数据仅在匹配重构误差右尾部及非匹配重构误差之和的左尾部发生交叠(图2)，因此分别对 \mathbf{R}_c^m 右尾部及 \mathbf{R}_c^{nm} 左尾部拟合GPD分

布, 最后根据式(5)、式(6)求得相应的极值参数。图3给出了某库外目标及库内目标利用字典重构的误差对比, 从图中可以看出库外目标重构误差大于库内目标重构误差。

3.2 测试阶段

在测试阶段, JDSR-OSR分类方法如算法3所示。对于一组待识别的多视数据 $\mathbf{Y}_j = [\mathbf{y}_{j1}, \mathbf{y}_{j2}, \dots, \mathbf{y}_{j(1+n)}]$, 通过JDSR来求解其稀疏系数, 得到其对应于字典 \mathbf{D} 的重构误差。传统的闭集方法将最小重构误差所对应的类别 c 作为输出类别, 在开集环境下还需考虑目标来自库外类别的情况。本文将类别 c 作为候选类, 在开集条件下进一步判断其是否属于库外新类。根据训练阶段得到的 $\hat{\sigma}_c^m, \hat{\gamma}_c^m, \hat{\sigma}_c^{nm}, \hat{\gamma}_c^{nm}$, 分别得到对应尾部分布的置信度作为匹配与非匹配的概率得分 $\text{score}_m, \text{score}_{nm}$ 。两概率得分分别代表待判决目标属于候选类及不属于闭集类别中非候选类的概率得分, 用于综合评判目标属于候选类的概率。本文利用两个概率得分的加权和, 得到最终的判别得分

$$\text{score} = \text{score}_m + w \cdot \text{score}_{nm} \quad (10)$$

其中 w 为权重。

通过设定判决阈值 δ_g , 即可判断目标类别

$$\left. \begin{array}{l} \text{score} > \delta_g, \\ \text{score} \leq \delta_g, \end{array} \right\} \begin{array}{l} \text{newclass} \\ c \end{array} \quad (11)$$

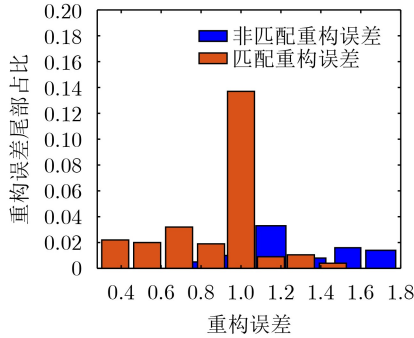


图2 部分拖尾分布示意图




图3 库内样本及库外样本重构误差对比

非匹配类得分受开放程度影响, 其权重应与 openness 负相关, 即与闭集程度 $1 - \text{openness}$ 正相关, 故其权重可设置为

$$w = p \cdot (1 - \text{openness}) \quad (12)$$

其中 $0 < p \leq 1$, $\text{openness} = 1 - \sqrt{\frac{2 \times N_{\text{TR}}}{N_{\text{TG}} + N_{\text{TE}}}}$ 表示开放程度^[6], N_{TR} 表示训练类别数, N_{TG} 表示目标类别数, N_{TE} 表示测试类别数。

3.3 性能评估

开放集条件下需综合考虑算法对库内目标及库外目标的识别性能, 本文借助准确率和 F 值来综合评判算法性能。准确率的定义如式(13)

$$\text{accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (13)$$

其中, TP, TN, FP, FN 分别代表真正类、真反类、假正类及假反类。

F 值通过精确率和召回率来表示如式(14)

$$F = 2 \cdot \frac{\text{recall} \cdot \text{precision}}{\text{recall} + \text{precision}} \quad (14)$$

其中, 召回率 $\text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$, 精确率 $\text{precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$ 。 F 值综合评判了准确率和召回率, 能体现一个识别系统的性能好坏。

4 实验结果及分析

本节利用从MSTAR反演的HRRP数据集验证所提算法的有效性。为体现算法的有效性, 将所提算法与3种主流开集识别方法进行了比对, 包括1-vs-set^[6], W-SVM^[7], SR-OSR^[9]和KLD-RPA^[14]。由于选取的对比算法无法直接采用多视数据作为输入, 因此对多视数据逐个输入, 在决策层融合表决, 其余条件不变。

算法3 JDSR-OSR分类方法

- 1 输入: 多视数据 $\mathbf{Y}_j, \mathbf{D}, k, \hat{\sigma}^m, \hat{\gamma}^m, \hat{\sigma}^{nm}, \hat{\gamma}^{nm}, \delta_g, w$
- 2 计算重构误差 $R \leftarrow \text{JDSR}(\mathbf{Y}_j, \mathbf{D}, K)$
- 3 得到候选类别 $c^* = \arg \min_i R_i$
- 4 $r^m = R_{c^*}^m, r^{nm} = \sum_{i \neq c^*} R_i$
- 5 $\text{score}_m = G(r^m; \hat{\sigma}^m(c^*), \hat{\gamma}^m(c^*)),$
 $\text{score}_{nm} = G(r^{nm}; \hat{\sigma}^{nm}(c^*), \hat{\gamma}^{nm}(c^*))$
- 6 $\text{score} = \text{score}_m + w \cdot \text{score}_{nm}$
if $\text{score} > \delta_g$
- $\mathbf{Y}_j \in \text{openset}$
- else
- $\text{Class}_{\mathbf{Y}_j} = c^*$
- 7 输出 \mathbf{Y}_j 类别

4.1 数据说明

由于缺少HRRP实测数据, 本文利用MSTAR公开数据集, 将其SAR数据反演生成HRRP数据用于实验。MSTAR包含了10类地面目标, 分别为BMP2, BTR70, T72, BTR60, 2S1, BRDM2, D7, T62, ZIL及ZSU。雷达工作于X波段, 采用聚束式成像, 图像分辨率 $0.3\text{ m}\times 0.3\text{ m}$, 每幅图像覆盖角约为 3° , 数据采集俯仰角为 15° 和 17° 。实验中 17° 数据用于训练, 15° 数据用于测试。SAR反演生成HRRP数据流程如图4^[21], SAR图像首先经过2维傅里叶逆变换(2D-IFFT), 然后对得到的数据解卷积消除加窗影响, 并剔除零元素, 再进行2维傅里叶变换, 并分割目标区域, 最后在方位向上作傅里叶逆变换即可得到反演HRRP数据。

4.2 实验安排

反演生成HRRP数据后, 取一定角度范围内HRRP的非相干平均松弛HRRP的姿态敏感性, 取2范数幅度归一化消除强度敏感性, 对数据进行幂变换增强数据特征。构建字典时需要遵循两个基本要求: (1)字典原子应包含不同类别以描述信号不同结构; (2)字典原子数应足够多以确保字典是过完备的。为满足上述要求, 本文采用人工构建法, 利用目标训练样本来构造过完备字典。对俯仰角 17° 的每幅SAR图像生成的HRRP数据按 3° 方位间隔提取非相干平均生成1幅HRRP数据, 按方位角顺序排序构建过完备字典。实验阶段通过提取相邻HRRP的非相干平均作为特征构建训练数据集。

为验证不同观测情形下分类器的识别性能, 本文预设两种不同观测情形: 多视观测从小角度范围内获取的情形, 记作Situation- I; 多视观测间无角度约束的情形, 记作Situation- II。

在Situation- I情形下, 所有观测均在不发生越距离单元走动的角度范围内获取, 多视数据间是强相关的。训练阶段对俯仰角 17° 的每幅SAR图像

按 0.1° 方位间隔提取非相干平均生成30幅HRRP并按方位角顺序排序, 在小角度范围内选取连续的 J 个观测数据构造多视观测样本, 实验参数设置多视观测数目 $J=5$, 设置JDSR稀疏度 $K=2$, 尾部大小 $\rho=0.7$, 依据3.1节所述算法流程计算重构误差并进行参数估计。测试阶段对俯仰角 15° 的每幅SAR图像按 0.3° 方位间隔提取非相干平均生成10幅HRRP并按方位角顺序排序, 多视观测样本的获取同训练阶段, 参数设置判决阈值 $\delta_g=0.3$, 依3.2节所述算法进行目标类型判断。

在Situation- II情形下, 多视数据间可能是强相关的也可能是弱相关的, 实验中将上述实验HRRP方位角顺序排序变更为随机排列, 并取100次Monte Carlo实验结果的均值作为最终结果, 其余操作不变。

4.3 实验结果

(1) 训练3类测试10类

实验中选取BMP2, BTR70及T72作为库内目标进行训练, 测试阶段加入其余7类库外目标进行测试(共10类)。表1和表2分别给出了Situation- I和Situation- II情形下JDSR-OSR的混淆矩阵, 混淆矩阵第1列表示测试样本对应的真实类别, 第1行表示分类器输出类别。表3给出了本文提出的JDSR-OSR与其他方法平均识别率的对比结果。结果显示本文算法在每个类别中均取得较高的识别率, 平均识别率也高于其他对比算法。

(2) 不同未知类别数下的识别结果

实验结果采用前3类目标(BMP2, BTR70, T72)作为库内目标, 依次增加BTR60, 2S1, BRDM2, D7, T62, ZIL及ZSU作为库外未知目标测试算法识别性能, 开放程度openness依次为7.42%, 13.4%, 18.35%, 22.54%, 26.15%, 29.29%, 32.06%。Situation- I的实验结果如图5所示; Situation- II的实验结果如图6所示。结果显示在两不同场景及不同开放程度下, 本文算法均取得了更好的性能。

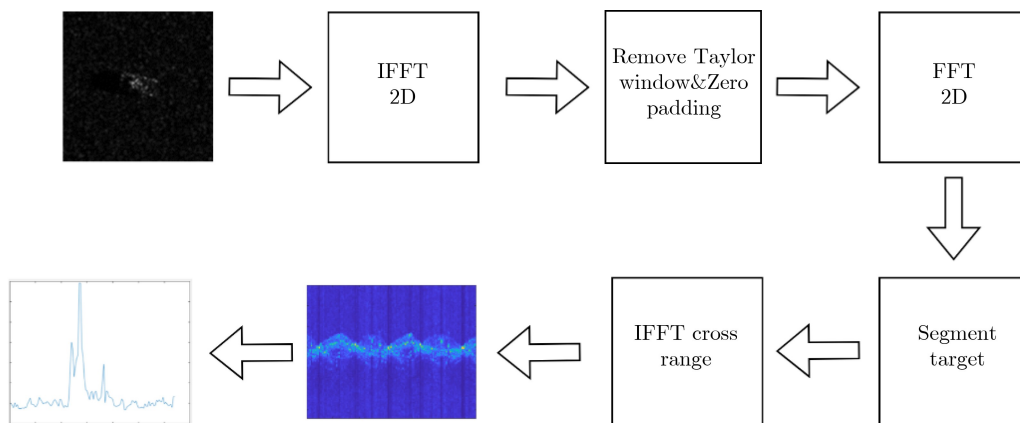


图4 SAR反演HRRP数据流程图

以上结果显示，本文提出方法在不同场景下都实现了最高的 F 值及准确率。由于 W-SVM 将训练数据视作同一类目标而忽视了类别间的差异，容易造成库内目标的错误判决；1-vs-set 通过基本 SVM 获取超平面并在另一侧添加平行超平面，为取得判决效果，决策边界会尽量围绕训练数据，但未采用极值理论，对于容易引起误判的“极端”数据难以区分；SR-OSR 算法无法利用数据来自同一目标的先验信息，获取稀疏系数时缺乏类别约束导致数据误判；KLD-RPA 算法通过神经网络对目标进行特征提取，并计算 Kullback-Leibler 散度和相对位置角，实现对目标的联合判别，但采用的神经网络相

对较浅，难以提取目标的深层特征；JDSR 能利用观测来自相同目标的先验信息提高识别精度，同时极值理论通过对拖尾的拟合提升了分类器对“极端”数据的判决，因此在 4 种方法中取得了最好的性能。

(3) 两场景结果对比

为验证所提方法在不同应用场景下的识别性能，实验对比了所提算法在两场景下的识别结果，并且选取了性能较好的 SR-OSR 算法结果进行对比，结果如图 7 所示。从图中结果可以看出所提算法在不同场景下均可取得更优的性能，对不同的应用场景在具有较好的鲁棒性。表 4 给出了基于 Intel

表 1 Situation-I JDSR-OSR 的混淆矩阵

类别	BMP2	BTR70	T72	未知新类
BMP2	0.712	0.088	0.060	0.140
BTR70	0.066	0.827	0.025	0.082
T72	0.030	0.007	0.825	0.138
BTR60	0.048	0.124	0.027	0.801
2S1	0.045	0.086	0.131	0.738
BRDM2	0.134	0.076	0.038	0.752
D7	0.011	0.010	0.080	0.899
T62	0.003	0	0.121	0.876
ZIL	0	0	0.051	0.949
ZSU	0	0	0.096	0.904

表 2 Situation-II JDSR-OSR 的混淆矩阵

类别	BMP2	BTR70	T72	未知新类
BMP2	0.735	0.056	0.019	0.190
BTR70	0.020	0.910	0.022	0.048
T72	0.005	0	0.960	0.035
BTR60	0.019	0.042	0.039	0.900
2S1	0.016	0.056	0.045	0.883
BRDM2	0.066	0.018	0	0.916
D7	0	0.002	0.247	0.751
T62	0	0	0.403	0.597
ZIL	0	0	0.177	0.823
ZSU	0	0	0.318	0.682




图 5 不同开放程度下的实验结果(Situation-I)






图 6 不同开放程度下的实验结果(Situation-II)



(R) Core(TM) i7-7820HQ CPU @ 2.90GHz硬件平台, 在Matlab2018上不同类别目标的算法运行时间(各类别样本数分别为975, 980, 980, 975, 1370, 1370, 1370, 1365, 1370, 1370)。结果表明本文算法JDSR-OSR与SR-OSR运行时间相当, 且本文算法具有更优异的识别性能。




图7 两场景实验结果对比

表3 JDSR-OSR与其他方法平均识别率的对比结果

方法	Situation- I	Situation- II
JDSR-OSR	0.832	0.816
SR-OSR	0.809	0.732
W-SVM	0.786	0.687
1-vs-set	0.794	0.709
KLD-RPA	0.813	0.752

表4 不同测试类别下的算法运行时间对比(s)

测试类别数	SR-OSR	JDSR-OSR
4	16.585	15.637
5	18.875	18.400
6	19.765	20.937
7	22.520	23.584
8	24.150	26.731
9	25.640	29.815
10	30.015	032.076

根据实验结果所示, 本文方法利用了JDSR算法能够利用多视观测来自相同目标的先验信息提升识别性能的优势, 在开集条件下开展对HRRP识别的实验验证, 在两种预设场景下的实验中, 均在4种算法中实现了最高的 F 值及准确率, 进一步说明了所提方法的有效性以及对不同场景的适应性。

5 结论

实际应用中雷达多站观测获取观测数据可能来自小角度间隔, 也可能角度间隔较大, 为解决不同场景下HRRP目标识别问题, 本文通过JDSR进行

图7结果显示了所提算法对不同应用场景具有较好的鲁棒性, 测试数据无角度约束条件下取得了更优异的效果, 这是因为在多视数目相同的条件下, 随机排列的数据具备更丰富的信息, 小角度范围内顺序排列的数据存在大量冗余信息, 而JDSR算法灵活利用了这些丰富信息因此取得了更优的性能。

信号重构, 并采用极值理论对误差尾部分布进行描述, 将JDSR应用于开集条件下的多视识别, 在MSTAR数据集上的实验结果表明所提方法优于许多开集识别方法。

本文方法通过JDSR能灵活描述多视观测间不同相关性的特点来提高开集条件下的目标识别性能。但算法在训练阶段需要一定的数据量以支撑尾部极值拟合, 在训练数据不足的条件下识别性能不够稳定, 小样本条件下的开集目标识别以及对增量数据的有效利用是后续值得研究的方向。

参考文献

- [1] 付哲泉, 李尚生, 李相平, 等. 基于高效可扩展改进残差结构神经网络的舰船目标识别技术[J]. 电子与信息学报, 2020, 42(12): 3005-3012. doi: 10.11999/JEIT190913.
- FU Zhequan, LI Shangsheng, LI Xiangping, et al. Ship target recognition based on highly efficient scalable improved residual structure neural network[J]. *Journal of Electronics & Information Technology*, 2020, 42(12): 3005-3012. doi: 10.11999/JEIT190913.
- [2] 贺丰收, 何友, 刘准钊, 等. 卷积神经网络在雷达自动目标识别中的研究进展[J]. 电子与信息学报, 2020, 42(1): 119-131. doi: 10.11999/JEIT180899.
- HE Fengshou, HE You, LIU Zhunga, et al. Research and development on applications of convolutional neural networks of radar automatic target recognition[J]. *Journal of Electronics & Information Technology*, 2020, 42(1): 119-131. doi: 10.11999/JEIT180899.
- [3] GÖRNITZ N, LIMA L A, MÜLLER K R, et al. Support vector data descriptions and k -means clustering: One

- class?[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(9): 3994–4006. doi: [10.1109/TNNLS.2017.2737941](https://doi.org/10.1109/TNNLS.2017.2737941).
- [4] PÉREZ G J, SANTIBÁÑEZ M, VALDOVINOS R M, *et al.* On-line learning with reject option[J]. *IEEE Latin America Transactions*, 2018, 16(1): 279–286. doi: [10.1109/TLA.2018.8291485](https://doi.org/10.1109/TLA.2018.8291485).
- [5] GEIFMAN Y and EL-YANIV R. Selective classification for deep neural networks[C]. Proceedings of the 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017: 4885–4894.
- [6] SCHEIRER W J, DE REZENDE ROCHA A, SAPKOTA A, *et al.* Toward open set recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(7): 1757–1772. doi: [10.1109/TPAMI.2012.256](https://doi.org/10.1109/TPAMI.2012.256).
- [7] SCHEIRER W J, JAIN L P, and BOULT T E. Probability models for open set recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(11): 2317–2324. doi: [10.1109/TPAMI.2014.2321392](https://doi.org/10.1109/TPAMI.2014.2321392).
- [8] JAIN L P, SCHEIRER W J, and BOULT T E. Multi-class open set recognition using probability of inclusion[C]. Proceedings of the 13th European Conference on Computer Vision, Zurich, Switzerland, 2014: 393–409. doi: [10.1007/978-3-319-10578-9_26](https://doi.org/10.1007/978-3-319-10578-9_26).
- [9] ZHANG He and PATEL V M. Sparse representation-based open set recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(8): 1690–1696. doi: [10.1109/TPAMI.2016.2613924](https://doi.org/10.1109/TPAMI.2016.2613924).
- [10] BENDALE A and BOULT T. Towards open world recognition[C]. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, USA, 2015: 1893–1902. doi: [10.1109/CVPR.2015.7298799](https://doi.org/10.1109/CVPR.2015.7298799).
- [11] SADHUKHAN P. Can reverse nearest neighbors perceive unknowns?[J]. *IEEE Access*, 2020, 8: 6316–6343. doi: [10.1109/ACCESS.2019.2963471](https://doi.org/10.1109/ACCESS.2019.2963471).
- [12] SHU Lei, XU Hu, and LIU Bing. DOC: Deep open classification of text documents[C]. Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, Copenhagen, Denmark, 2017: 2911–2916. doi: [10.18653/v1/D17-1314](https://doi.org/10.18653/v1/D17-1314).
- [13] OZA P and PATEL V M. C2AE: Class conditioned auto-encoder for open-set recognition[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, USA, 2019: 2302–2311. doi: [10.1109/CVPR.2019.00241](https://doi.org/10.1109/CVPR.2019.00241).
- [14] ZENG Zhiqiang, SUN Jinping, XU Congan, *et al.* Unknown SAR target identification method based on feature extraction network and KLD–RPA joint discrimination[J]. *Remote Sensing*, 2021, 13(15): 2901. doi: [10.3390/rs13152901](https://doi.org/10.3390/rs13152901).
- [15] RUDD E M, JAIN L P, SCHEIRER W J, *et al.* The extreme value machine[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(3): 762–768. doi: [10.1109/TPAMI.2017.2707495](https://doi.org/10.1109/TPAMI.2017.2707495).
- [16] PAPPADÀ R, PERRONE E, DURANTE F, *et al.* Spin-off extreme value and Archimedean copulas for estimating the bivariate structural risk[J]. *Stochastic Environmental Research and Risk Assessment*, 2016, 30(1): 327–342. doi: [10.1007/s00477-015-1103-8](https://doi.org/10.1007/s00477-015-1103-8).
- [17] FALK M and STUPFLER G. An offspring of multivariate extreme value theory: The max-characteristic function[J]. *Journal of Multivariate Analysis*, 2017, 154: 85–95. doi: [10.1016/j.jmva.2016.10.007](https://doi.org/10.1016/j.jmva.2016.10.007).
- [18] 刘盛启. 基于高分辨距离像的特征提取与识别增强技术研究[D]. [博士学位], 国防科学技术大学, 2016.
LIU Shengqi. Research on feature extraction and recognition performance enhancement algorithms based on high range resolution profile[D]. [Ph. D. dissertation], National University of Defense Technology, 2016.
- [19] AL-LABADI L and ZAREPOUR M. Two-sample Kolmogorov-Smirnov test using a Bayesian nonparametric approach[J]. *Mathematical Methods of Statistics*, 2017, 26(3): 212–225. doi: [10.3103/S1066530717030048](https://doi.org/10.3103/S1066530717030048).
- [20] 刘振. 基于稀疏表示的图像分类若干新方法研究[D]. [博士学位], 江南大学, 2021. doi: [10.27169/d.cnki.gwqgu.2021.001957](https://doi.org/10.27169/d.cnki.gwqgu.2021.001957).
LIU Zhen. Research on new methods of image classification via sparse representation[D]. [Ph. D. dissertation], Jiangnan University, 2021. doi: [10.27169/d.cnki.gwqgu.2021.001957](https://doi.org/10.27169/d.cnki.gwqgu.2021.001957).
- [21] 缪吴霞. SAR图像回波反演及典型目标特征提取方法研究[D]. [硕士学位论文], 哈尔滨工业大学, 2019. doi: [10.27061/d.cnki.ghgdu.2019.001165](https://doi.org/10.27061/d.cnki.ghgdu.2019.001165).
MIAO Wuxia. Research on SAR image echo inversion and typical target feature extraction method[D]. [Master dissertation], Harbin Institute of Technology, 2019. doi: [10.27061/d.cnki.ghgdu.2019.001165](https://doi.org/10.27061/d.cnki.ghgdu.2019.001165).
- 刘盛启: 男, 副研究员, 研究方向为雷达目标识别与跟踪。
张会强: 男, 博士, 研究方向为雷达信号处理、自动目标识别。
滕书华: 男, 副教授, 研究方向为雷达信号处理。
瞿爽: 男, 硕士, 研究方向为雷达信号处理。
吴中杰: 男, 讲师, 研究方向为认知雷达、雷达目标特性与识别等。

责任编辑: 于青