

基于直方图分析和自适应遗传的雷达道路目标识别特征优选方法

瓦其日体^① 李刚^① 赵志纯^{*②③} 则正华^①

^①(清华大学电子工程系 北京 100084)

^②(深圳北理莫斯科大学 深圳 518172)

^③(广东省智能感知与计算普通高校重点实验室 深圳 518172)

摘要: 在雷达道路目标识别领域, 目标类别多变且特性相近时增加目标特征维数是一种提高识别性能常用的手段。然而特征维数的增多会导致特征冗余和维数灾难, 因此需对提取的高维特征集进行优选, 基于随机搜索的自适应遗传算法(AGA)是一种有效的特征优选方法。为提升AGA算法的特征优选效率和精度, 现有方法通常通过引入特征与目标种类的先验相关度对高维特征集进行预降维, 然而此类算法仅考虑了单个特征与目标的相关性, 忽略了特征组合与目标类别的匹配度, 使得优选出的特征集不一定是目标的最佳识别组合。针对该问题, 该文通过引入直方图分析对不同特征组合与目标类别的匹配度加以研究, 提出了一种新的改进自适应遗传(HA-AGA)特征优选方法, 在提升特征优选效率和精度的同时提升目标的识别性能。基于毫米波雷达实测数据集的对比实验表明, 所提出的HA-AGA方法的目标识别平均精确率可达95.7%, 分别比IG-GA, ReliefF-IAGA和改进RetinaNet方法提升了1.9%, 2.4%和10.1%。基于公共数据集CARRADA的对比实验表明, 所提出的HA-AGA方法的目标识别平均精确率达到93.0%, 分别比IG-GA和ReliefF-IAGA方法提升了1.2%和1.5%, 验证了所提方法的有效性和优越性。此外, 还进行了不同特征优选方法分别结合集成装袋树、精细树和K-最邻近(KNN)分类器的性能对比, 实验结果表明所提方法结合不同分类器均具有明显优势, 具有一定的广泛适用性。

关键词: 自适应遗传算法; 特征优选; 直方图分析; 目标识别; 毫米波雷达

中图分类号: TN959.1

文献标识码: A

文章编号: 2095-283X(2023)05-1014-17

DOI: 10.12000/JR22245

引用格式: 瓦其日体, 李刚, 赵志纯, 等. 基于直方图分析和自适应遗传的雷达道路目标识别特征优选方法[J]. 雷达学报, 2023, 12(5): 1014–1030. doi: 10.12000/JR22245.

Reference format: WAQI Riti, LI Gang, ZHAO Zhichun, *et al.* Feature selection method of radar-based road target recognition via histogram analysis and adaptive genetics[J]. *Journal of Radars*, 2023, 12(5): 1014–1030. doi: 10.12000/JR22245.

Feature Selection Method of Radar-based Road Target Recognition via Histogram Analysis and Adaptive Genetics

WAQI Riti^① LI Gang^① ZHAO Zhichun^{*②③} ZE Zhenghua^①

^①(Department of Electronic Engineering, Tsinghua University, Beijing 100084, China)

^②(Shenzhen MSU-BIT University, Shenzhen 518172, China)

^③(Guangdong Laboratory of Machine Perception and Intelligent Computing, Shenzhen 518172, China)

Abstract: In radar-based road target recognition, the increase in target feature dimension is a common technique to improve recognition performance when targets become diverse, but their characteristics are similar.

收稿日期: 2022-12-31; 改回日期: 2023-02-22; 网络出版: 2023-03-13

*通信作者: 赵志纯 zzc@smbu.edu.cn *Corresponding Author: ZHAO Zhichun, zzc@smbu.edu.cn

基金项目: 国家自然科学基金(62101304, 61925106), 华为技术有限公司委托研发项目

Foundation Items: The National Natural Science Foundation of China (62101304, 61925106), Research and development project commissioned by Huawei Technologies Co. LTD

责任编辑: 唐世阳 Corresponding Editor: TANG Shiyang

©The Author(s) 2023. This is an open access article under the CC-BY 4.0 License

(<https://creativecommons.org/licenses/by/4.0/>)

However, the increase in feature dimension leads to feature redundancy and dimension disasters. Therefore, it is necessary to optimize the extracted high-dimensional feature set. The Adaptive Genetic Algorithm (AGA) based on random search is an effective feature optimization method. To improve the efficiency and accuracy of the AGA, the existing improved AGA methods generally utilize the prior correlation between features and targets for pre-dimensionality reduction of high-dimensional feature sets. However, such algorithms only consider the correlation between a single feature and a target, neglecting the correlation between feature combinations and targets. The selected feature set may not be the best recognition combination for the target. Thus, to address this issue, this study proposes an improved AGA via pre-dimensionality reduction based on Histogram Analysis (HA) of the correlation between different feature combinations and targets. The proposed method can simultaneously improve the efficiency and accuracy of feature selection and target recognition performance. Comparative experiments based on a real dataset of the millimeter-wave radar showed that the average accuracy of target recognition of the proposed HA-AGA method could reach 95.7%, which is 1.9%, 2.4%, and 10.1% higher than that of IG-GA, ReliefF-IAGA, and improved RetinaNet methods, respectively. Comparative experiments based on the CARRADA dataset showed that the average accuracy of target recognition of the proposed HA-AGA method could reach 93.0%, which is 1.2% and 1.5% higher than that of IG-GA and ReliefF-IAGA methods, respectively. These results verify the effectiveness and superiority of the proposed method compared with existing methods. In addition, the performance of different feature optimization methods coupled with the integrated bagging tree, fine tree, and K-Nearest Neighbor (KNN) classifier was compared. The experimental results showed that the proposed method exhibits evident advantages when coupled with different classifiers and has broad applicability.

Key words: Adaptive Genetic Algorithm (AGA); Feature selection; Histogram Analysis (HA); Target recognition; Millimeter-wave radar

1 引言

近年来,毫米波雷达因其能够穿透雨、雾、烟、灰尘,不受光照条件影响而全天时、全天候工作^[1],同时还具有体积小、重量轻、空间分辨能力高^[2]等优点而受到道路运动目标识别领域的广泛关注。道路目标的运动特性使同一目标的不同散射点的距离和速度信息更容易被毫米波雷达观测到,因此距离多普勒(Range-Doppler, RD)谱被广泛应用于雷达道路目标识别领域^[3]。在得到目标的RD谱之后,提取和目标相关的微动和微距特征对目标进行有效识别。雷达目标识别领域特征提取时可依据自动和手动分为两类,自动特征提取一般是将RD谱、合成孔径雷达(Synthetic Aperture Radar, SAR)图像等直接输入到神经网络中从而获得大量的特征,比如文献^[3]提出了一种融合卷积神经网络和长短时记忆网络的方法对RD谱进行特征提取从而完成对人体跌倒的检测。文献^[4,5]利用深度学习方法对海上舰船的SAR图像进行检测识别,实验表明RetinaNet及其改进的网络是近年来雷达目标识别领域深度学习方法中性能较好的网络之一。文献^[6]则将RD谱和改进的RetinaNet网络相结合,对自行车、汽车、行人和货车等道路目标进行分类识别,实验表明相比于VGG16+FPN+BN+data enhancement, ResNet50+FPN+BN+data enhancement, ResNet101+FPN+BN+data enhancement等5种网络,改进RetinaNet的识别性能最优。

虽然深度学习网络能够自动提取特征,但它们对抽象特征和大数据集的过度依赖,完全舍弃了传统成熟的手动特征,给特定目标的针对性学习以及识别准确性的进一步提升带来限制^[7]。而手动特征提取通过充分利用目标的先验信息,对目标的RD谱分布进行统计分析提取具有针对性的特征,从而达到对特定目标分类的效果。比如文献^[8]通过对RD谱提取散射点个数、目标散射点占距离单元个数、目标散射点占速度单元个数等特征完成对行人和汽车的有效识别。文献^[9]通过对RD谱提取径向速度、距离维峰值信号方差和速度维峰值信号方差等特征完成对行人、横向汽车以及纵向汽车的分类。上述方法利用较少数量的特征完成了对目标的有效识别,但是在目标种类多变且目标特性相近时,上述方法的性能受限。针对上述问题,通过增大特征数量来提高识别性能是一个常用的有效方法。然而特征维数的增多,不但会造成维数灾难^[10],有时甚至会因为特征向量包含有和目标无关的信息导致识别性能降低^[11]。因此,从所提取的高维特征集中进一步优选得到使识别性能更高的特征组合,就显得尤为重要。

目标识别领域的特征选择方法一般可分为过滤法和包装法^[12]两类,其中过滤法是根据信息论^[13]、主成分分析(Principal Component Analysis, PCA)^[14]等特定的统计标准对特征进行排序^[15],之后选取前 N 维特征作为新的特征集从而达到特征优

选的目的。文献[16]针对人体目标识别中人体微多普勒特征的优选问题,提出用互信息计算特征的贡献值作为特征的物理相关性和估计质量的函数,从而对特征重要度进行排序,实现了特征优选和对人体运动状态的有效识别。文献[17]针对5类飞机目标的分类识别问题,通过利用PCA对波形熵、中心矩和信号幅度方差等特征进行降维,该方法虽然特征选择时效较高,但是特征评估函数与学习器相互独立,导致目标总体识别率不高。过滤法具有计算量小、特征选择时效较高的优点[18],但是由于此类方法的特征选择操作和后续的分类模型是相互独立的[19],往往使得分类性能受限。包装法则依赖于机器学习,利用筛选后的特征子集训练分类器,根据验证样本在分类器中的学习性能来评价特征子集的优劣[12]。遗传算法(Genetic Algorithm, GA)是最常用的包装式特征选择算法之一,文献[20]针对极化合成孔径雷达(SAR)图像分类提出了一种基于GA特征选择的分层分类算法,得到了更好的识别效果。文献[21]首次将GA应用于SAR图像的特征选择中,用GA和贝叶斯鉴别器得到最优特征组合。文献[22]提出了一种基于GA的SAR图像监测系统,用于洪涝灾害的检测。但是当特征维数增多时,特征组合数呈指数型增长,导致GA随机搜索时无法快速收敛获得最优解[23],这一缺陷限制了GA在高维特征集中特征选择领域的应用。针对这一问题,文献[24,25]提出了一种PCA和GA相结合(PCA-GA)的特征选择算法,先利用PCA算法对原始特征集进行降维,将降维后的特征输入到GA加快特征选择算法的收敛速度。然而该算法在特征集预降维阶段仅考虑了特征间的相关性,未对特征组合与目标类别的匹配度进行考虑,从而使得识别性能受限。文献[26,27]提出了一种基于ReliefF的改进自适应遗传(ReliefF-IAGA)特征选择算法,该算法首先使用ReliefF算法获得特征重要性得分,并消除不相关的特征,接着利用自适应遗传算法(Adaptive Genetic Algorithm, AGA)得到优选特征子集。文献[28]提出了基于信息增益(Information Gain, IG)和GA (IG-GA)的特征选择方法,首先利用IG得到每个特征的信息增益值作为预降维依据,设定阈值对待选特征集进行预降维后利用GA得到最终的特征子集。然而上述方法在预降维阶段仅考虑了单个特征与目标类别的相关性或者信息增益,忽略了特征组合与目标类别的相关性,导致优选后的特征组合对目标类别的区分度有限。

针对该问题,本文通过在自适应遗传算法框架中引入直方图分析[29]考虑不同特征组合与目标类别

的相关性,提出了一种基于直方图分析和自适应遗传(Adaptive Genetic Algorithm via Histogram Analysis, HA-AGA)的雷达道路目标识别特征优选方法。该算法首先通过AGA迭代搜索得到由各代平均F测度最高的特征组合构成的特征组合库,接着引入直方图分析统计该特征组合库中各特征的分布频次。频次较高的特征构成的特征组合与目标类别匹配度更高,因此选取频次最高的 K 维特征输入到AGA优选出使目标识别精度更高的特征组合。基于毫米波雷达实测数据集和公共数据集CARRADA[30]上的实验表明,与PCA-GA[24,25], ReliefF-IAGA[26,27], IG-GA[28] 3种方法相比,本文提出的方法选出的特征组合与目标类别相关度更高,能够得到更高的识别准确率。

2 自适应遗传算法

自适应遗传算法[26]是对传统遗传算法[31]的遗传操作步骤进行改进得到的具有随机搜索特性的优化方法,具体算法流程如下:

步骤1 参数初始化。将待优选特征集中的各特征组合以“基因”的形式编码成染色体 \mathbf{x} 。编码规则可根据实际情况选择二进制编码、浮点数编码以及符号编码等方式。随机生成 M 条染色体组成初始种群 $\mathbf{W}_1 = \{\mathbf{x}_{11} \mathbf{x}_{12} \cdots \mathbf{x}_{1M}\}$,染色体 \mathbf{x}_{ij} 表示第 i 代的第 j 个特征组合。

步骤2 搜索迭代。假设迭代 $i-1$ 次后得到第 i 代种群 $\mathbf{W}_i = \{\mathbf{x}_{i1} \mathbf{x}_{i2} \cdots \mathbf{x}_{iM}\}$,为判断第 i 代种群 \mathbf{W}_i 里各特征组合的优劣,并给接下来的自适应遗传操作提供依据,由式(1)计算每个特征组合的适应度:

$$\text{fitness}_{ij} = F(\mathbf{x}_{ij}) \quad (1)$$

其中,操作 F 是将该特征组合输入到机器学习分类器后得到相应的适应度 fitness_{ij} ,对 \mathbf{W}_i 中的每一个特征组合都计算适应度后得到第 i 代种群的适应度向量 $\mathbf{FIT}_i = [\text{fitness}_{i1} \text{fitness}_{i2} \cdots \text{fitness}_{iM}]$ 。接着对 \mathbf{W}_i 进行双重轮盘赌选择,将 $\mathbf{W}_i = \{\mathbf{x}_{i1} \mathbf{x}_{i2} \cdots \mathbf{x}_{iM}\}$ 中所有染色体根据适应度向量 \mathbf{FIT}_i 从大到小进行排序得到 $\mathbf{W}'_i = \{\mathbf{y}_{i1} \mathbf{y}_{i2} \cdots \mathbf{y}_{iM}\}$,染色体 \mathbf{y}_{ij} 被选择的概率为

$$P_{ij} = \text{fitness}_{\mathbf{y}_{ij}} / \sum_{j=1}^M \text{fitness}_{\mathbf{y}_{ij}} \quad (2)$$

得到 $\mathbf{W}'_i = \{\mathbf{y}_{i1} \mathbf{y}_{i2} \cdots \mathbf{y}_{iM}\}$ 中所有染色体被选择的概率后,将 $[0,1]$ 根据 \mathbf{W}'_i 中每条染色体被选择的概率分成 M 段,接着随机生成 M 个 $[0,1]$ 之间的数,染色体被选择的概率越大,对应的区间长度越长,随

机产生的数字落入该区间的概率越大，统计落在各个片段的数量，并选择数量最多的片段对应的染色体 z_{i1} 存入种群 W_i'' ，则适应度越大的染色体被选中的概率越大。重复选择直到 $|W_i''| = M$ ，选择完成后得到 $W_i'' = \{z_{i1} z_{i2} \dots z_{iM}\}$ 。然后进行自适应交叉，对于 W_i'' 中的染色体 z_{ij} (j 依次取 1, 2, ..., M)，在 W_i'' 里剩下的染色体中随机选取另一条染色体 z_{im} ($m \neq j$)，从 z_{im} 中随机选取一个基因与 z_{ij} 中相同位置的基因以概率 P_c 进行互换得到新的染色体 v_{ij} ，遍历所有染色体得到 $W_i''' = \{v_{i1} v_{i2} \dots v_{iM}\}$ 。最后进行自适应变异，对于 W_i''' 中的染色体 v_{ij} (j 依次取 1, 2, ..., M)，随机选取某个基因以概率 P_m 进行突变得到新的染色体，遍历所有染色体后得到下一代种群 W_{i+1} 。其中自适应交叉概率 P_c 和变异概率 P_m 为

$$P_c = P_m = \begin{cases} P_{a0}, & \text{fitness}_j > \text{fitness}_{\text{avg}} \\ \frac{P_{a0} (\text{fitness}_{\text{max}} - \text{fitness}_j)}{\text{fitness}_{\text{max}} - \text{fitness}_{\text{avg}}}, & \text{fitness}_j \leq \text{fitness}_{\text{avg}} \end{cases} \quad (3)$$

其中， P_{a0} 为设定的初始交叉或变异概率， fitness_j ($j=1, 2, \dots, M$) 为各染色体对应的适应度， $\text{fitness}_{\text{max}}$ 为当代最优适应度， $\text{fitness}_{\text{avg}}$ 为当代平均适应度。

步骤3 重复步骤2直到进化代数达到预设的最大代数 I 。当迭代结束后适应度最高的特征组合即为最终选择结果。

3 基于直方图分析的改进自适应遗传特征优选方法

3.1 RD谱特征集的构建

为对道路目标进行有效识别，本文所提方法对目标RD谱中的散射点分布特点进行统计分析提取

波形熵、能量密度等30个特征构建RD谱特征集。在特征提取之前需要对雷达回波数据进行预处理得到只包含单个目标信息的RD谱，具体处理流程如图1所示。在得到雷达回波后首先进行2DFFT得到原始RD谱^[3]，接着将RD谱中径向速度小于某个预设的速度参数值 v 的速度单元置零，去除静止或者低速度杂波。然后运用2D-CFAR算法进行目标检测，去除其他噪声从而得到只包含目标信息的RD谱。最后判断目标个数，若为单个目标，则直接得到只包含单个目标信息的RD谱；若为多个目标，则利用DBSCAN算法对不同目标的特征数据进行切割，得到只包含单个目标信息的RD谱，并根据雷达回波对应的光学视频对RD谱中的目标进行区分和标注。预处理完成后，根据RD谱中散射点的分布特点，分别从RD谱的距离维、速度维和距离速度两维联合分布进行统计分析提取平均距离、平均速度、能量密度、波形熵等30个特征构建高维特征集 $F = [f_1 f_2 \dots f_{30}]$ ，如表1所示。其中， s 表示RD谱的散射点个数， r_i, v_i 和 A_i ($i = 1, 2, \dots, s$) 分别表示每个散射点对应的距离、速度和幅值， $N \times M$ 为RD谱的尺寸， $A(n, m)$ 表示位于 (n, m) 点的散射点幅值， A_g ($g = 1, 2, \dots, G$) 表示每个距离单元(或速度单元)里幅值最大的散射点的幅值， G 表示某个目标的RD谱中散射点占据的距离单元(或速度单元)

个数， $p_g = \frac{(A_g + \sigma)}{\sum_{g=1}^G (A_g + \sigma)}$ ， $\sigma \ll A_g$ 表示距离(或速度)维峰值点所占的比重， $\bar{A}_G = \frac{1}{G} \sum_{g=1}^G A_g$ 表示距离(或速度)维平均幅值， $p_{n,m} = \frac{A(n, m)}{\sum_{i=0}^{N-1} \sum_{j=0}^{M-1} A(i, j)}$ 表示该点幅值占所有点幅值中的比重， \bar{n} 和 \bar{m} 分别表示距离维方向和速度维方向上的质心，

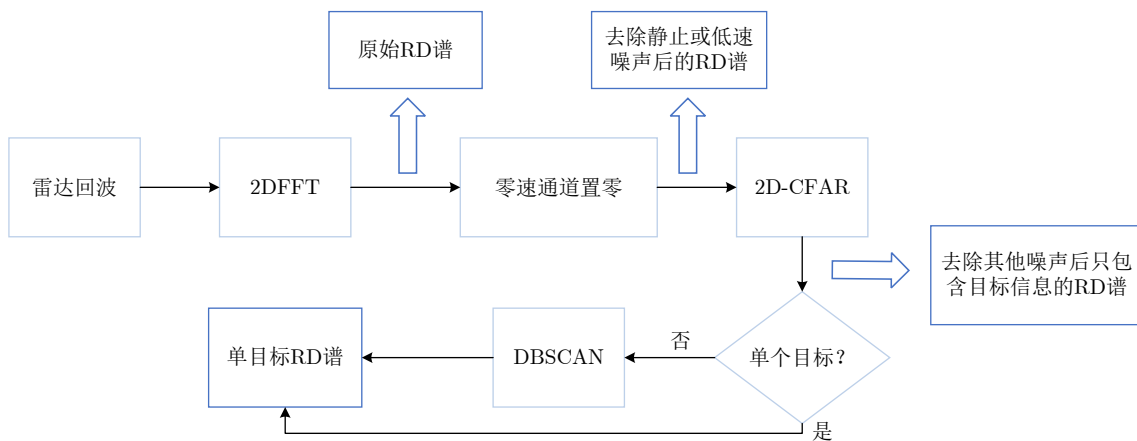


图1 数据预处理流程图

Fig. 1 Data preprocessing flow chart

表 1 特征及其公式
Tab. 1 Features and formulas

序号	特征	公式	序号	特征	公式
1	峰值点距离	$f_1 = r_t$	16	最大距离点速度与峰值点速度差	$f_{16} = f_{14} - f_{11}$
2	平均距离	$f_2 = \frac{1}{s} \sum_{i=1}^s r_i$	17	速度宽	$f_{17} = \max(v_i) - \min(v_i)$
3	最小距离点距离	$f_3 = \min(r_i)$	18	速度维中值	$f_{18} = \frac{\max(v_i) + \min(v_i)}{2}$
4	最大距离点距离	$f_4 = \max(r_i)$	19	速度维方差	$f_{19} = \frac{1}{G} \sum_{g=1}^G (A_g - \bar{A}_G)^2$
5	峰值点距离与最小距离差	$f_5 = f_1 - f_3$	20	速度维熵	$f_{20} = - \sum_{g=1}^G p_g \lg(p_g)$
6	最大距离与峰值点距离差	$f_6 = f_4 - f_1$	21	散射点个数	$f_{21} = s$
7	距离宽	$f_7 = \max(r_i) - \min(r_i)$	22	距离宽比速度宽	$f_{22} = \frac{f_7}{f_{17}}$
8	距离维中值	$f_8 = \frac{\max(r_i) + \min(r_i)}{2}$	23	能量密度	$f_{23} = \frac{1}{s} \sum_{i=1}^s A_i^2$
9	距离维方差	$f_9 = \frac{1}{G} \sum_{g=1}^G (A_g - \bar{A}_G)^2$	24	波形熵	$f_{24} = - \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} p_{n,m} \lg(p_{n,m})$
10	距离维熵	$f_{10} = - \sum_{g=1}^G p_g \lg(p_g)$	25	2阶中心矩	$f_{25} = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} (n - \bar{n})(m - \bar{m})A(n, m)$
11	峰值点速度	$f_{11} = v_t$	26	4阶中心矩	$f_{26} = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} (n - \bar{n})^2(m - \bar{m})^2 A(n, m)$
12	平均速度	$f_{12} = \frac{1}{s} \sum_{i=1}^s v_i$	27	信号幅值方差	$f_{27} = \frac{1}{s} \sum_{i=1}^s (A_i - \bar{A})^2$
13	最小距离点速度	$f_{13} = v_{r_{\min}}$	28	主分量能量	$f_{28} = \sum_{j=1}^n \text{main_energy}_j$
14	最大距离点速度	$f_{14} = v_{r_{\max}}$	29	副分量能量	$f_{29} = \sum_{i=1}^s A_i^2 - \sum_{j=1}^n \text{main_energy}_j$
15	峰值点速度与最小距离点速度差	$f_{15} = f_{11} - f_{13}$	30	主副能量比	$f_{30} = \frac{f_{28}}{f_{29}}$

$\bar{A} = 1/s \sum_{i=1}^s A_i$ 表示所有散射点的平均幅值。峰值点及其周围 T 个点均为主分量，剩下的点为副分量。

3.2 基于直方图分析的特征优选

为了加快AGA的收敛速度，通过充分考虑不同特征组合与目标类别的匹配度对待选特征集进行预降维并保留与目标类别相关度较高的特征组合。该方法具体流程如图2所示，描述如下：

步骤1 根据AGA算法对特征组合进行编码，本文采用的编码方式为二进制编码，假设待选特征集 $F = [f_1 f_2 \dots f_N]$ 总共有 N 个特征，则编码后的特征组合 x 由 N 个“0”，“1”构成，且“0”，“1”的组合形式由特征组所包含的特征编号决定，比如 x 为“0101100”，代表该特征组合由第2号、第4号和第5号特征组成。编码完成后，随机生成 M 个特征组合作为接下来进行搜索迭代的初始特征组合库 $F_1 = \{x_{11} x_{12} \dots x_{1M}\}$ ，其中 x_{ij} 表示第 i 代的第 j 个特征组合编码之后的染色体。

步骤2 迭代搜索优秀特征组合库。假设迭代 $i - 1$ 次后得到第 i 代特征组合库 $F_i = \{x_{i1} x_{i2} \dots x_{iM}\}$ ，为对 F_i 中的每个特征组合的优劣提供评价指标，给各代最优特征组合的选择提供依据，进行特征组合适应度的计算。假设所有目标同等重要，且本文所提算法旨在优选出使目标识别性能更好的特征组合，因此将 x_{ij} 对应的数据集按一定比例随机分成训练集和测试集，对分类器进行训练和测试后分类器输出的平均F测度作为该特征组合的适应度 fitness_{ij} ，平均F测度的计算公式为

$$\text{fitness}_{ij} = \frac{1}{T} \sum_{m=1}^T \frac{2P_m R_m}{P_m + R_m} \tag{4}$$

其中， T 为目标种类数， $P_m = TP_m / (TP_m + TN_m)$ 和 $R_m = TP_m / (TP_m + FN_m)$ 分别为第 m 类目标的精确率和召回率。TP, TN和FN分别为真正例、真反例和假反例^[32]。适应度越高，则该特征组合与目标类别的匹配度越高，识别性能越好。对 F_i 中的所有

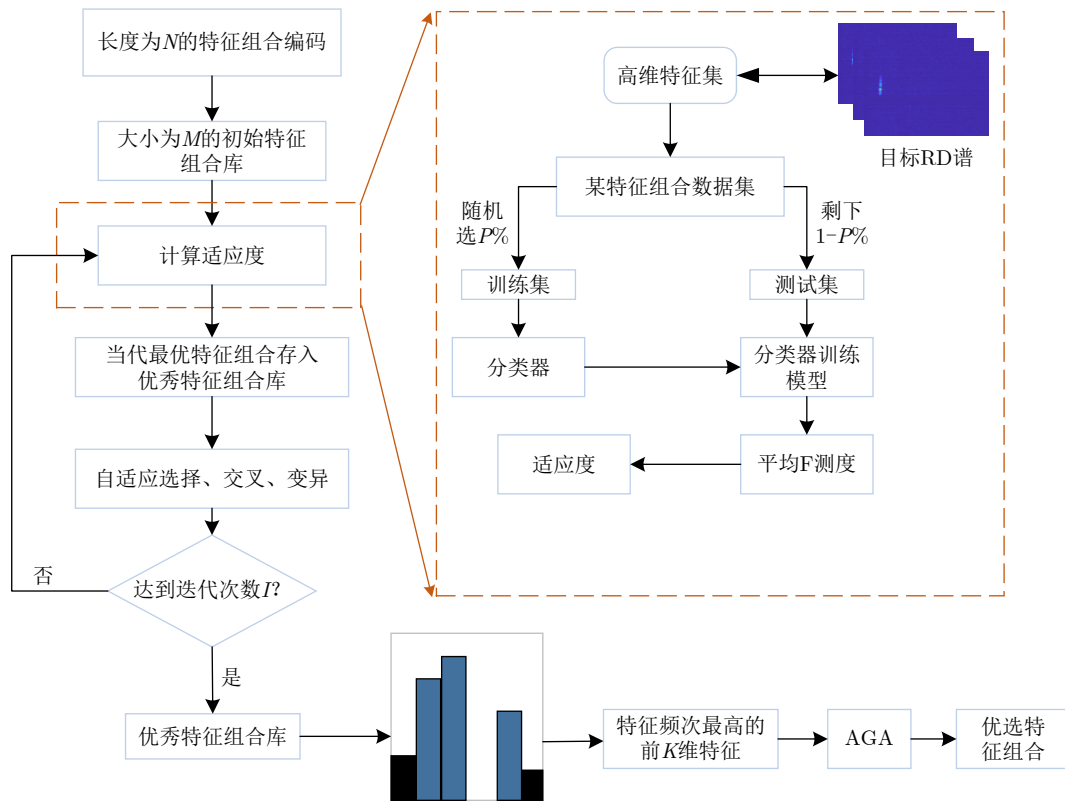


图 2 基于直方图分析的特征优选流程图

Fig. 2 Flow chart of feature optimization via histogram analysis

特征组合依次计算适应度得到 F_i 相应的适应度向量 $\mathbf{FIT}_i = [\text{fitness}_{i1} \ \text{fitness}_{i2} \ \dots \ \text{fitness}_{iM}]$ ，根据 \mathbf{FIT}_i 找到 F_i 中适应度最高的特征组合 \mathbf{x}_{ib} ，将其存入优秀特征组合库 F_{best} 中。存储完成后，通过对 F_i 依次进行双重轮盘赌选择、自适应交叉和自适应变异 3 个步骤得到下一代特征组合库 F_{i+1} ，再对 F_{i+1} 重复执行以上操作，不断地进行迭代搜索直到迭代次数达到预设的最大迭代次数 I 。迭代终止后，输出迭代 I 次得到的优秀特征组合库 $F_{\text{best}} = \{\mathbf{x}_{1b}, \mathbf{x}_{2b}, \dots, \mathbf{x}_{Ib}\}$ 。

步骤 3 为给待选特征集 $F = [f_1 \ f_2 \ \dots \ f_N]^T$ 的预降维提供有效的特征选择依据，提高降维后的特征组合与目标类别的匹配度，利用直方图分析方法对步骤 2 得到的优秀特征组合库 F_{best} 中每个特征出现的频次进行统计，将第 i 号特征 $f_i (i=1, 2, \dots, N)$ 在优秀特征组合库 F_{best} 中出现的频次 $q_i (i=1, 2, \dots, N)$ 作为该特征的权重，遍历所有特征，最终得到待选特征集 $F = [f_1 \ f_2 \ \dots \ f_N]$ 对应的权重向量 $Q = [q_1 \ q_2 \ \dots \ q_N]$ 。权重越大的特征，其组合与目标类别的相关度越高，因此取权重最大的前 $K (K < N)$ 维特征构成新的特征子集 $F' = [f'_1 \ f'_2 \ \dots \ f'_K]^T$ ，其中 K 过大则达不到降维的效果， K 过小则可能会丢失与目标匹配度更高的特征组合。一般通过 K 取不同值进行算法性能比较，根据实际应用需求确定 K 的取值。

步骤 4 为进一步去除预降维后的特征子集 F' 中的冗余特征，将 F' 输入到 AGA 进行优选得到最终的特征组合。

通过 HA-AGA 得到优选的特征组合后，将该特征组合的数据集划分成训练集和测试集，并将训练集输入分类器进行模型训练和测试，得到最终的目标分类识别结果。

4 实验验证

为验证本文提出的算法的有效性，将本文所提的 HA-AGA 算法和 PCA-GA^[24,25], ReliefF-IAGA^[26,27], IG-GA^[28] 3 种两阶段特征选择算法在毫米波雷达实测数据集和公开数据集 CARRADA^[30] 两个不同的数据集上进行比较，以验证本文所提算法的有效性和优越性。

4.1 毫米波实测雷达数据实验

4.1.1 实验设置

在实验过程中，将毫米波雷达架设在路口、天桥(均为面向道路水平放置)等地方对行人、电动车、自行车、小汽车、货车和公交车 6 类道路目标进行测量采集，采集完成后首先进行数据预处理，其中去除静止或低速度杂波时的速度参数值 v 设为 0.4 m/s，某个场景及其对应的雷达回波预处理结

果如图3所示。雷达回波中包含有如图3(a)场景所示的公交车和大货车。图3(b)为该场景对应的原始RD谱, 图3(c)为去除静止或低速度杂波后的RD谱, 图3(d)为经2D-CFAR检测并去噪后的RD谱, 因为该RD谱包含有两个目标, 利用DBSCAN算法将不

同目标分割开, 图3(e)和图3(f)分别为数据切割后只包含公交车和货车信息的RD谱。预处理完成后得到有效数据共14607帧, 将每类目标的数据按7:3的比例分为训练集和测试集进行特征选择与识别实验。表2为各目标类别的标签以及训练集和测试集的数

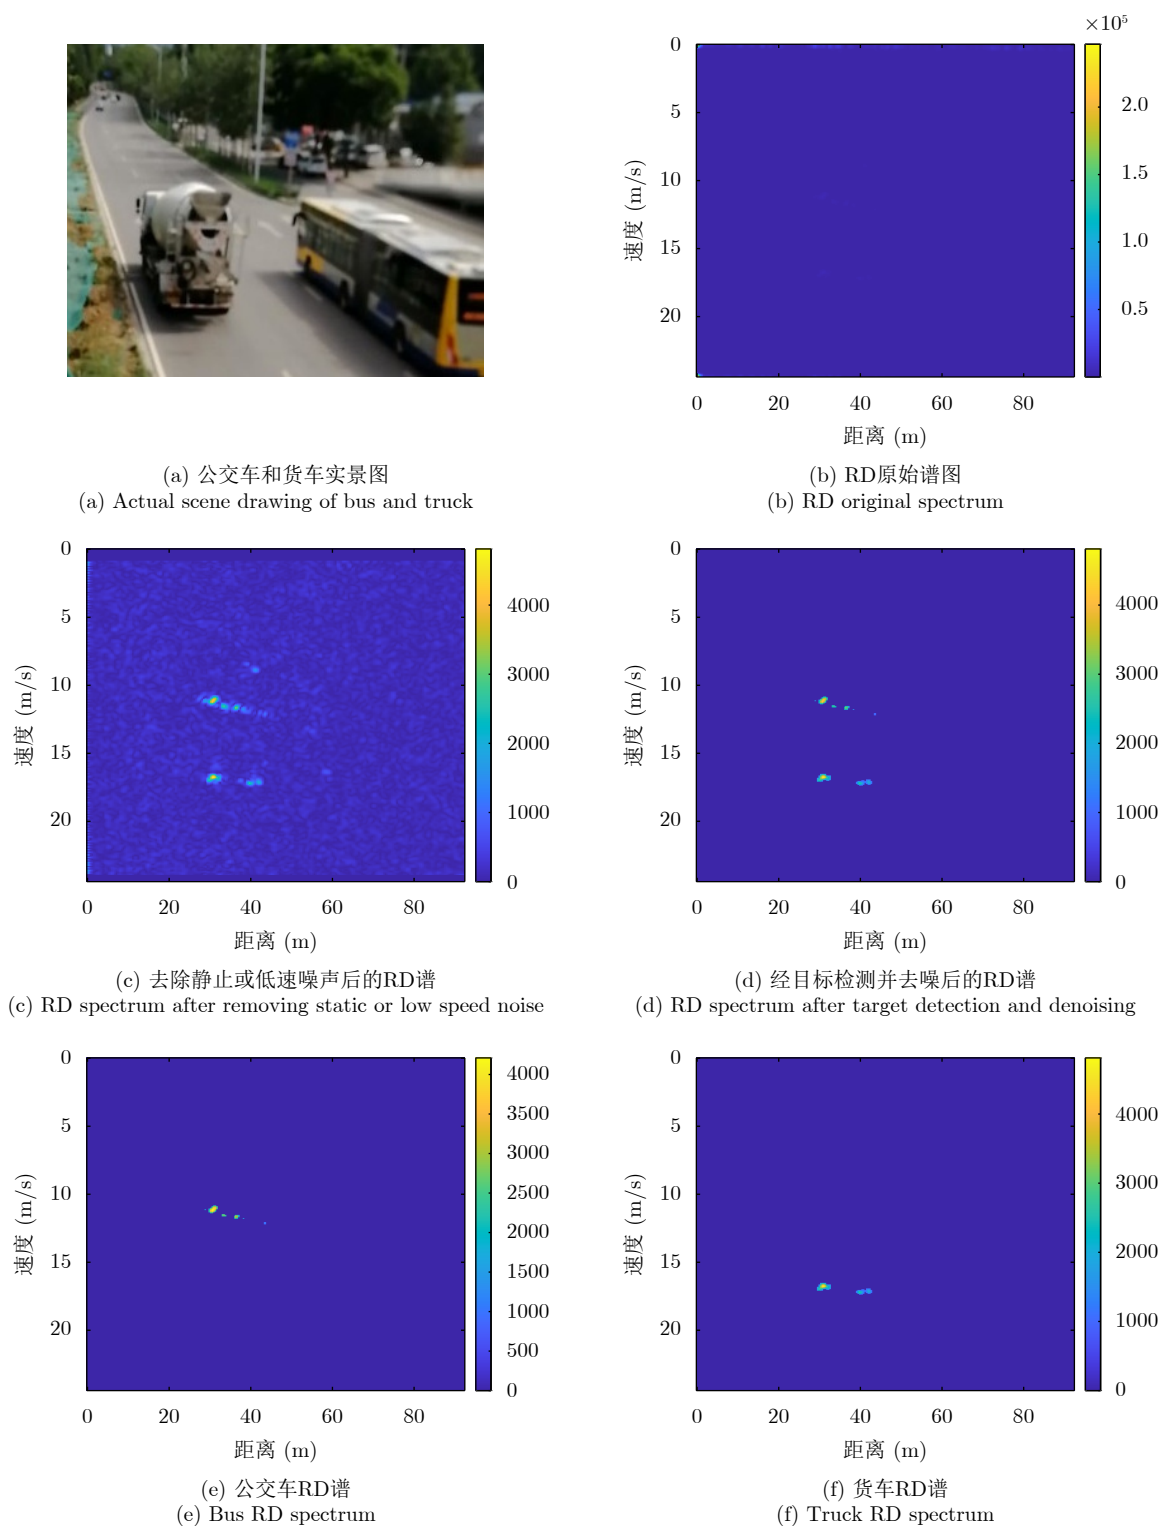


图 3 数据预处理各步骤实验结果

Fig. 3 Experimental results of each step of data preprocessing

量。具体的雷达参数如表3所示。该雷达体制为线性调频连续锯齿波，包含4个接收通道，载频为24 GHz，带宽为207.32 MHz，调频斜率为0.80986，采样率为1 MHz，每帧持续时间为32.768 ms且包含128个脉冲，每个脉冲采样点数为256。各目标实际场景以及相应的RD谱如图4所示，由图可看出行人和自行车的散射点占据的距离单元的个数(距离宽)明显比速度单元的个数(速度宽)少，而货车和公交车的情况恰好相反，电动车和小汽车的散射点占据的距离单元和速度单元的个数都很少。并且小汽车、货车和公交车的径向速度大于行人、电动车和自行车的径向速度，说明各目标的RD谱散射点分布存在差异，通过提取相应的特征可对道路目标进行有效识别。

进行特征选择实验时首先从道路目标RD谱提取如表1所示的高维特征集 $F = [f_1 f_2 \dots f_{30}]$ 作为待选特征集。HA-AGA的种群大小 M ，初始交叉概率 P_{c0} 和初始变异概率 P_{m0} 分别设为20, 0.5和0.2，预降维阶段和优选阶段的最大迭代次数 M 分别设为100和50。PCA-GA, ReliefF-IAGA, IG-GA 3种算法的种群大小和迭代次数均设为20和50。各算法取权重最大的前20维特征 ($K=20$) 作为预降维后的特征子集。

4.1.2 实验结果与分析

为验证本文所提方法在特征优选方面的优越

表 2 实测数据集描述

Tab. 2 The real radar dataset description

类别	标签	训练集(帧)	测试集(帧)
行人	1	2981	1278
电动车	2	2727	1169
自行车	3	111	48
小汽车	4	1756	753
货车	5	1162	499
公交车	6	1486	637

表 3 雷达参数

Tab. 3 Radar parameters

参数	数值
载频(GHz)	24
带宽(MHz)	207.32
波形斜率(MHz/ μ s)	0.80986
采样率(MHz)	1
每个脉冲采样点数	256
帧脉冲数	128
接收通道数	4
帧持续时长(ms)	32.768

性，进行了不同算法结合集成装袋树的特征预降维和优选的对比实验，预降维实验中 K 的值从2取到20，得到的实验结果如图5所示，可知HA-AGA在 K 取不同值时得到的平均F测度均最高，表明本文提出的特征权重计算方法更加合理有效。且PCA-GA方法和其他3种方法相比，识别性能较差，因此在接下来的对比实验中将不再比较PCA-GA算法。特征优选实验结果如图6所示，可知本文所提方法在第5代即收敛，收敛速度最快且识别效果最好，各算法最终选出的特征组合如表4所示，本文所提方法和ReliefF-IAGA方法均选出了14维特征，IG-GA选出了11维特征，但IG-GA选出的特征组合的识别效果最差。本文所提方法特征优选前后的特征向量经PCA降维后的可视化分布图如图7所示。其中图7(a)为优选前的特征分布图，可知各目标的特征分布混叠较为严重，对目标的可分性较差。图7(b)为优选后的特征分布图，可看出各目标经过特征优选后的特征分布较分散，对目标的可分性较好。将优选前的特征集和各算法优选得到的特征组合分别输入到集成装袋树分类器进行目标识别实验，识别结果如表5所示，可知HA-AGA方法的识别效果最好，特别是平均精确率、平均召回率和平均F测度分别达到95.7%, 93.0%和94.2%，分别比未进行特征优选时提高了1.8%, 1.9%和2.0%，说明原特征集中确实存在特征冗余；比IG-GA提高了1.9%, 2.1%和2.0%；比ReliefF-IAGA提高了2.4%, 2.0%和2.3%。由此可知HA-AGA方法选出了与类别相关度更高的特征组合，选择效果更好。

在利用集成装袋树分类器实验的基础上，为进一步分析和验证所提特征优选算法结合不同分类器对于其他特征优选算法的优势，将各算法分别与精细树和 K 最近邻 (K -Nearest Neighbor, KNN) 相结合进行实验，优选后的识别结果如表6和表7所示，可知与IG-GA, ReliefF-IAGA算法和未进行特征优选前相比，本文所提的HA-AGA算法结合不同分类器均具有不同程度的优势，表明所提算法具有一定的广泛适用性。

为进一步验证本文所提方法的优越性，将本文所提方法和深度学习方法即改进的RetinaNet^[6]进行对比实验，实验识别结果如表8所示。由表可看出本文所提方法与深度学习方法改进的RetinaNet相比，得到的所有指标均最高，表明了本文所提方法能得到更好的识别结果。

为验证本文所提方法的鲁棒性，进行了不同信噪比条件下各算法特征选择对比实验。实验结果如图8所示，可知，在-10 dB和-5 dB条件下各算法

识别精度都很差,但总体而言,在不同信噪比条件下本文所提的HA-AGA算法均获得了最高的平均精确率,表明本文所提的HA-AGA特征优选方法对噪声具有更好的容忍性。

4.2 公共数据集CARRADA实验


4.2.1 实验设置

公共数据集CARRADA^[30]提供了包括两个场

景在内的行人、自行车和小汽车3类目标的RD谱,数据集所用雷达参数如表9^[30]所示。该雷达载频为77 GHz,带宽为4 GHz,帧脉冲数为64,每个脉冲采样点数为256,最大探测距离为50 m,距离分辨率为0.20 m,最大径向速度为13.43 m/s,速度分辨率为0.42 m/s。首先通过对该数据集筛选并进行数据预处理,去除静止或低速度杂波时的速度参数 v 设为0.4 m/s。某个场景对应的雷达回波预处理实




(a) 行人
(a) Pedestrian



(b) 行人对应的RD谱
(b) RD spectrum of pedestrian




(c) 电动车
(c) Motorbike



(d) 电动车对应的RD谱
(d) RD spectrum of motorbike




(e) 自行车
(e) Bicycle



(f) 自行车对应的RD谱
(f) RD spectrum of bicycle




(g) 小汽车
(g) Car



(h) 小汽车对应的RD谱
(h) RD spectrum of car




(i) 货车
(i) Truck



(j) 货车对应的RD谱
(j) RD spectrum of truck



(k) 公交车
(k) Bus



(l) 公交车对应的RD谱
(l) RD spectrum of bus

图4 各类目标及其对应的RD谱

Fig. 4 All kinds of targets and their corresponding RD spectrum

验结果如图9所示。雷达回波中包含有如图9(a)场景所示的自行车和小汽车，自行车向远离雷达方向行驶，小汽车低速靠近。图9(b)为该场景对应的原始RD谱，图9(c)为去除静止或低速度杂波后的RD谱，图9(d)为经2D-CFAR检测并去噪后的RD谱，因为该RD谱包含有两个目标，利用DBSCAN算法将不

同目标分割开，图9(e)和图9(f)分别为数据切割后只包含小汽车或自行车信息的RD谱。预处理完成后得到有效数据8693帧，接着对每帧RD谱提取特征向量 $F = [f_1 \ f_2 \ \dots \ f_{30}]$ 构成RD谱特征集。将每类目标的数据按7:3的比例分为训练集和测试集，进行实验时各目标的类别标签以及训练集和测试集的

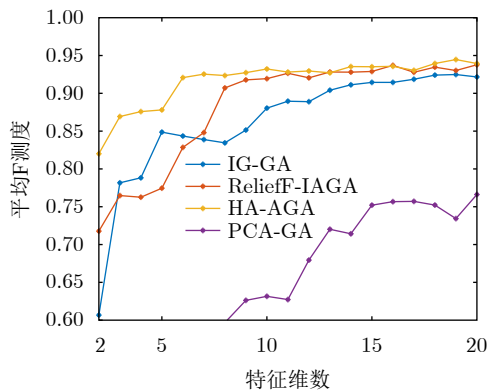


图 5 各算法特征预降维结果

Fig. 5 Pre-dimensionality reduction results of different algorithms

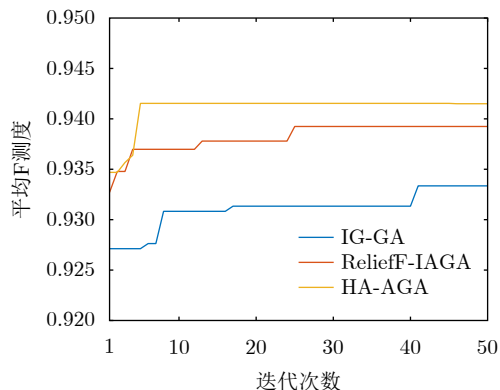


图 6 各算法特征优选结果

Fig. 6 Feature optimization results of different algorithms

表 4 各算法优选后的特征组合

Tab. 4 Feature combination of different algorithms after optimization

特征选择算法	优选后特征组合
IG-GA	$f_2, f_8, f_{10}, f_{11}, f_{12}, f_{22}, f_{24}, f_{26}, f_{27}, f_{28}, f_{29}$
ReliefF-IAGA	$f_1, f_2, f_3, f_4, f_5, f_6, f_8, f_{10}, f_{12}, f_{17}, f_{18}, f_{20}, f_{22}, f_{25}$
HA-AGA	$f_1, f_3, f_5, f_7, f_8, f_{10}, f_{11}, f_{12}, f_{14}, f_{17}, f_{20}, f_{22}, f_{23}, f_{24}$




图 7 由PCA降维得到的实测数据集特征优选前后可视化分布图

Fig. 7 Visual distribution of real data set features before and after optimization obtained by PCA dimension reduction

表 5 各算法结合集成装袋树优选后识别结果(实测数据集)(%)

Tab. 5 Recognition result of different algorithms combined with integrated bagging tree after optimization (Real radar dataset) (%)

类别	未优选	IG-GA	ReliefF-IAGA	HA-AGA
	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度
行人	99.0/95.7/97.3	98.3/96.7/97.5	98.4/96.6/97.5	99.0/96.8/97.9
电动车	94.3/ 99.1 /96.6	95.3/98.2/96.7	95.5/98.1/96.8	95.5/98.8/97.1
自行车	87.2/70.8/78.2	92.5/77.1/84.1	85.7/75.0/80.0	95.0/79.2/86.4
小汽车	97.6/98.3/98.0	96.1/97.3/96.7	97.8/ 98.9 /98.3	98.1/98.5/98.3
货车	94.8 /85.4/90.0	91.2/84.1/87.5	91.4/84.3/87.7	93.5/ 89.5 / 91.5
公交车	90.4/ 95.9 /93.1	89.1/92.2/90.7	89.2/93.2/91.2	92.9/94.9/93.9
平均值	93.9/91.1/92.2	93.8/90.9/92.2	93.3/91.0/91.9	95.7/93.0/94.2

表 6 各算法结合精细树优选后识别结果(实测数据集)(%)

Tab. 6 Recognition result of different algorithms combined with fine tree after optimization (Real radar dataset) (%)

类别	未优选	IG-GA	Relieff-IAGA	HA-AGA
	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度
行人	99.1/94.3/96.6	99.1/94.2/96.6	99.5 /94.0/96.7	99.3/ 94.7 / 97.0
电动车	92.3/98.9/95.6	92.5/99.0/95.6	92.5/98.9/95.7	92.7 / 99.0 / 95.7
自行车	75.6/64.6/70.0	84.6/68.8/75.9	88.4/70.2/78.2	89.5 / 70.8 / 79.1
小汽车	96.5/97.4/96.8	95.9/93.5/94.7	97.5 /97.0/ 97.1	96.4/ 97.5 /97.0
货车	86.2/76.7/81.2	83.7/ 84.9 /84.3	88.6/78.6/83.3	89.6 /80.4/ 84.8
公交车	82.9/90.0/86.3	88.4 /89.2/88.8	85.3/ 91.6 /88.3	86.8/91.4/ 89.0
平均值	88.7/87.0/87.8	90.7/88.3/89.3	92.0/88.3/89.9	92.4 / 89.0 / 90.4

表 7 各算法结合KNN优选后识别结果(实测数据集)(%)

Tab. 7 Recognition result of different algorithms combined with KNN after optimization (Real radar dataset) (%)

类别	未优选	IG-GA	Relieff-IAGA	HA-AGA
	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度
行人	94.6/93.6/94.1	96.0/ 94.8 /95.5	96.0/94.3/95.1	96.3 /94.6/ 95.5
电动车	91.9/94.3/93.1	92.7/ 96.1 / 94.3	92.2/95.2/93.7	92.7 /95.7/94.2
自行车	70.7/60.4/65.2	87.5 /72.9/79.6	84.7/75.0/79.5	86.0/ 77.1 / 81.3
小汽车	96.7/96.6/96.7	96.7/95.8/96.3	96.1/97.0/96.5	96.7 / 97.1 / 97.0
货车	88.6/83.3/85.9	85.7/82.5/84.5	87.2/82.8/84.9	89.6 / 83.3 / 86.3
公交车	87.8/91.0/89.3	87.9/89.4/88.6	90.0 /90.0/90.0	88.4/ 91.6 / 90.0
平均值	88.4/86.4/87.4	91.1/88.6/89.8	91.0/89.0/89.9	91.6 / 89.9 / 91.0

表 8 HA-AGA与改进的RetinaNet方法的识别结果(%)

Tab. 8 Recognition results of HA-AGA and the improved RetinaNet method (%)

类别	改进的RetinaNet	HA-AGA
	精确率/召回率/F测度	精确率/召回率/F测度
行人	98.1/95.6/96.8	99.0 / 96.8 / 97.9
电动车	87.4/92.0/89.6	95.5 / 98.8 / 97.1
自行车	81.8/56.3/66.7	95.0 / 79.2 / 86.4
小汽车	80.2/84.5/82.3	98.1 / 98.5 / 98.3
货车	82.3/67.1/73.9	93.5 / 89.5 / 91.5
公交车	83.8/88.7/86.2	92.9 / 94.9 / 93.9
平均值	85.6/80.7/82.6	95.7 / 93.0 / 94.2

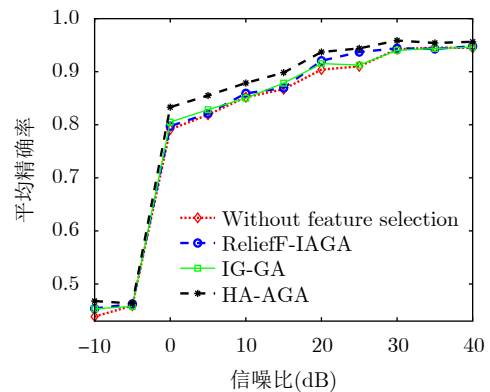


图 8 不同信噪比条件下各特征选择算法识别结果

Fig. 8 The recognition results of feature selection algorithm in different SNR

数量如表10所示。特征选择实验中各特征选择算法的参数设置和4.1.1节一致。

4.2.2 实验结果与分析

为验证本文所提方法的优越性，进行了不同算法结合集成装袋树特征预降维和优选的对比实验，预降维实验中K的值从2取到20，实验结果如图10所示，可知HA-AGA在K取不同值时得到的平均F测度均最高，表明本文提出的特征权重计算方法

表 9 CARRADA数据集雷达参数^[30]

Tab. 9 Radar parameters of CARRADA dataset^[30]

参数	数值
载频(GHz)	77
带宽(GHz)	4
最大距离(m)	50
FFT距离分辨率(m)	0.20
最大径向速度(m/s)	13.43
FFT径向速度分辨率(m/s)	0.42
每个脉冲采样点数	256
帧脉冲数	64

更加合理有效。特征优选的实验结果如图11所示，本文所提方法在第4代即收敛，收敛速度最快且识别效果最好，各算法最终选出的特征组合如表11所示。本文所提方法特征优选前后的特征向量经PCA降维后的可视化分布图如图12所示。其中图12(a)

为优选前的特征分布图，可看出各目标的特征分布混为一簇，对目标的可分性较差。图12(b)为优选后的特征分布图，可知各目标的特征分布较分散，对目标的可分性有所提升。将优选前的特征集和各算法优选得到的特征组合分别输入到集成装袋树分

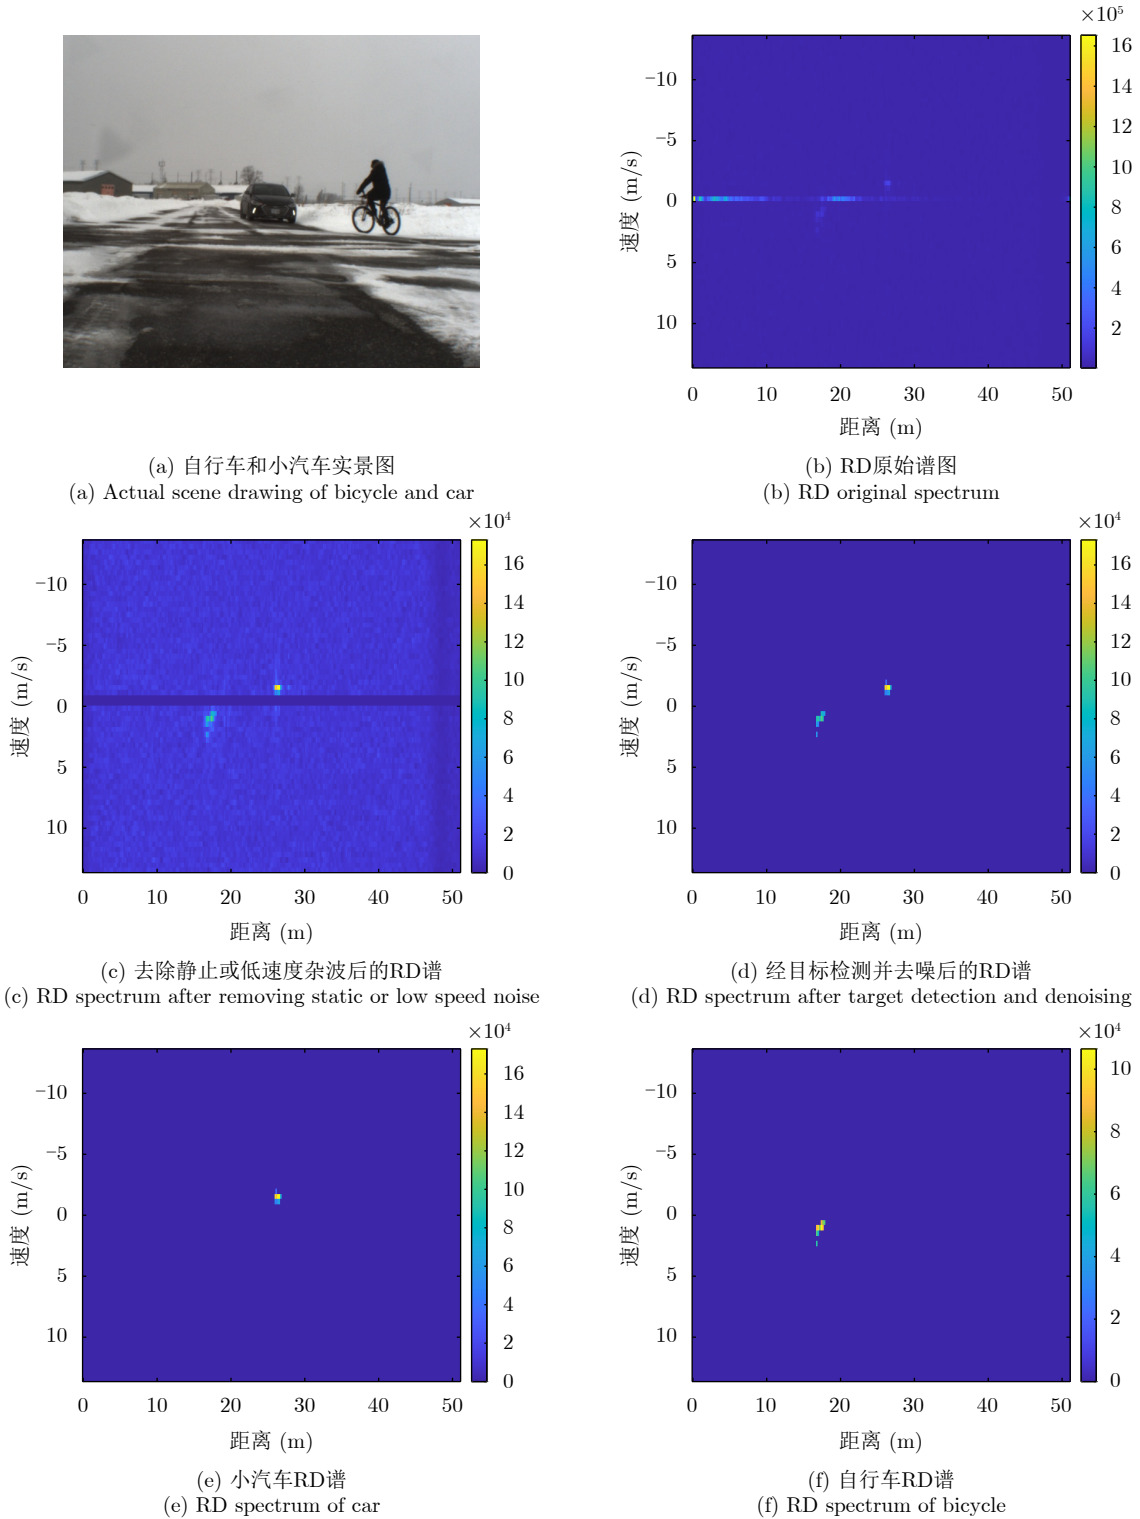


图 9 数据预处理各步骤实验结果

Fig. 9 Experimental results of each step of data preprocessing

类器进行目标识别实验，识别结果如表12所示，可知HA-AGA方法的识别效果最好，平均精确率、平

均召回率和平均F测度分别达到93.0%，92.4%和92.7%，分别比未进行特征优选时提高了2.0%，1.7%

表 10 CARRADA数据集描述
Tab. 10 CARRADA dataset description

类别	标签	训练集(帧)	测试集(帧)
行人	1	2383	1021
自行车	2	1309	561
小汽车	3	2393	1026

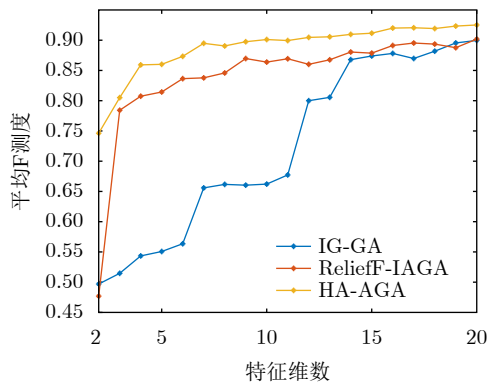


图 10 不同算法特征预降维结果

Fig. 10 Pre-dimensionality reduction results of different algorithms

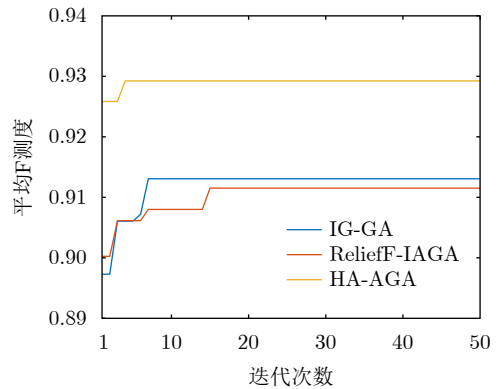



图 11 不同算法特征优选结果


Fig. 11 Feature optimization results of different algorithms

表 11 不同算法优选后的特征组合
Tab. 11 Feature combination of different algorithms after optimization

特征选择算法	优选后特征组合
IG-GA	$f_2, f_4, f_7, f_8, f_{12}, f_{13}, f_{18}, f_{20}, f_{22}, f_{23}, f_{26}$
ReliefF-IAGA	$f_1, f_4, f_5, f_7, f_8, f_{12}, f_{13}, f_{18}, f_{23}, f_{26}, f_{27}, f_{30}$
HA-AGA	$f_1, f_2, f_3, f_4, f_6, f_7, f_8, f_{12}, f_{13}, f_{17}, f_{18}, f_{21}, f_{23}, f_{28}$



(a) 特征优选前
(a) Before feature optimization



(b) 特征优选后
(b) After feature optimization

图 12 由PCA降维得到的CARRADA数据集特征优选前后可视化分布图

Fig. 12 Visual distribution of CARRADA data set features before and after optimization obtained by PCA dimension reduction

表 12 各算法结合集成装袋树优选后识别结果(CARRADA)(%)

Tab. 12 Recognition result of different algorithms combined with integrated bagging tree after optimization (CARRADA) (%)

类别	未优选	IG-GA	ReliefF-IAGA	HA-AGA
	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度
行人	90.3/93.3/91.8	90.5/94.4/92.4	89.8/94.4/92.1	91.7/95.2/93.4
自行车	85.1/83.4/84.3	87.2/83.6/85.4	87.2/82.4/84.7	89.5/85.4/87.4
小汽车	97.6/95.4/96.5	97.6/95.6/96.6	97.4/95.4/96.4	97.7/96.5/97.1
平均值	91.0/90.7/90.9	91.8/91.2/91.5	91.5/90.7/91.1	93.0/92.4/92.7

和1.8%；比IG-GA均提高了1.2%；比Relief-IAGA提高了1.5%，1.7%和1.6%。由此可知HA-AGA方法选出了与类别相关度更高的特征组合，验证了本文所提方法的优越性。

在利用集成装袋树分类器实验的基础上，为进一步分析和验证所提特征优选算法结合不同分类器

对于其他特征优选算法的优势，将各算法分别与精细树和KNN相结合进行实验，优选后的识别结果如表13和表14所示，可知与IG-GA, Relief-IAGA算法和未进行特征优选前相比，本文所提的HA-AGA算法结合不同分类器均具有不同程度的优势，表明所提算法具有一定的广泛适用性。

表 13 各算法结合精细树优选后识别结果(CARRADA)(%)

Tab. 13 Recognition result of different algorithms combined with fine tree after optimization (CARRADA) (%)

类别	未优选	IG-GA	Relief-IAGA	HA-AGA
	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度
行人	87.5/86.7/87.1	86.9/86.6/86.8	84.0/88.0/86.0	88.0/87.3/87.7
自行车	74.8/80.6/77.6	71.4/80.4/75.6	73.5/76.3/74.9	72.8/83.1/77.6
小汽车	95.5/92.4/93.9	96.5/90.2/93.2	96.2/89.8/92.9	97.6/90.9/94.2
平均值	85.9/86.6/86.2	84.9/85.7/85.2	84.5/84.7/84.6	86.0/87.1/86.5

表 14 各算法结合KNN优选后识别结果(CARRADA)(%)

Tab. 14 Recognition result of different algorithms combined with KNN after optimization (CARRADA) (%)

类别	未优选	IG-GA	Relief-IAGA	HA-AGA
	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度	精确率/召回率/F测度
行人	84.9/86.2/85.5	88.1/87.5/87.8	86.5/84.4/85.5	88.7/88.7/88.7
自行车	76.4/75.4/75.9	76.7/75.6/76.2	74.1/75.9/75.0	76.9/79.1/78.0
小汽车	93.0/92.2/92.6	93.4/94.7/94.1	92.4/93.4/92.9	93.1/91.6/92.3
平均值	84.8/84.6/84.7	86.1/85.9/86.0	84.3/84.6/84.5	86.2/86.5/86.4

在毫米波雷达实测数据集和公共数据集CARRADA上的实验表明，与Relief-IAGA, IG-GA, 未进行特征优选前和改进的RetinaNet网络相比，本文所提的HA-AGA方法获得了与目标类别相关度更高的特征组合，提高了目标的识别精度，且在实测数据集中的信噪比对比实验验证了本文所提算法具有更好的噪声鲁棒性。

5 结语

随着自动驾驶技术的不断发展，道路目标识别领域中的特征优选技术受到社会各界的广泛关注。本文针对现有改进AGA特征优选方法因未考虑不同特征组合与目标类别的匹配度从而导致优选得到的特征组合对目标的区分度有限的问题，提出了一种基于直方图分析和自适应遗传的雷达道路目标识别特征优选方法。该方法在AGA框架中通过引入直方图分析对优秀特征组合库中各特征的频次进行统计，并选取频次最高的特征集输入AGA优选出与目标类别相关度更高的特征组合，以提升特征优选的效率和准确度。基于毫米波雷达实测数据集和公共数据集CARRADA的一系列对比实验表明与

PCA-GA, Relief-IAGA和IG-GA等特征选择方法相比，本文所提方法结合不同分类器选出的特征组合与类别相关度最高，能够得到更高的识别精度，且对噪声的鲁棒性更强，适用性更加广泛。

参 考 文 献

- [1] PATOLE S M, TORLAK M, WANG Dan, *et al.* Automotive radars: A review of signal processing techniques[J]. *IEEE Signal Processing Magazine*, 2017, 34(2): 22-35. doi: 10.1109/MSP.2016.2628914.
- [2] 周刚, 吴杰. 汽车防撞毫米波雷达系统参数优化设计[J]. 电讯技术, 2011, 51(7): 77-80. doi: 10.3969/j.issn.1001-893x.2011.07.016.
ZHOU Gang and WU Jie. Parameters optimized design of automobile anti-collision millimeter wave radar system[J]. *Telecommunication Engineering*, 2011, 51(7): 77-80. doi: 10.3969/j.issn.1001-893x.2011.07.016.
- [3] 元志安, 周笑宇, 刘心溥, 等. 基于RDSNet的毫米波雷达人体跌倒检测方法[J]. 雷达学报, 2021, 10(4): 656-664. doi: 10.12000/JR21015.
YUAN Zhian, ZHOU Xiaoyu, LIU Xinpu, *et al.* Human fall detection method using millimeter-wave radar based on

- RDSNet[J]. *Journal of Radars*, 2021, 10(4): 656–664. doi: [10.12000/JR21015](https://doi.org/10.12000/JR21015).
- [4] ZHAO Yan, ZHAO Lingjun, XIONG Boli, *et al.* Attention receptive pyramid network for ship detection in SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 2738–2756. doi: [10.1109/JSTARS.2020.2997081](https://doi.org/10.1109/JSTARS.2020.2997081).
- [5] MIAO Tian, ZENG Hongcheng, YANG Wei, *et al.* An improved lightweight RetinaNet for ship detection in SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 4667–4679. doi: [10.1109/JSTARS.2022.3180159](https://doi.org/10.1109/JSTARS.2022.3180159).
- [6] WANG Chenxi, CHEN Zhichao, CHEN Xin, *et al.* Detection of MMW radar target based on Doppler characteristics and deep learning[C]. IEEE International Conference on Artificial Intelligence and Industrial Design, Guangzhou, China, 2021: 266–271. doi: [10.1109/AIID51893.2021.9456497](https://doi.org/10.1109/AIID51893.2021.9456497).
- [7] ZHANG Tianwen, ZHANG Xiaoling, KE Xiao, *et al.* HOG-ShipCLSNet: A novel deep learning network with HOG feature fusion for SAR ship classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5210322. doi: [10.1109/TGRS.2021.3082759](https://doi.org/10.1109/TGRS.2021.3082759).
- [8] SOROWKA P and ROHLING H. Pedestrian classification with 24 GHz chirp sequence radar[C]. 2015 16th International Radar Symposium, Munich, Germany, 2015: 167–173. doi: [10.1109/IRS.2015.7226392](https://doi.org/10.1109/IRS.2015.7226392).
- [9] 余月琴. 车载毫米波雷达行人识别算法研究[D]. [硕士学位论文], 电子科技大学, 2020: 11–15.
YU Yueqin. Research on pedestrian recognition algorithm of automobile millimeter wave radar[D]. [Master dissertation], University of Electronic Science and Technology of China, 2020: 11–15.
- [10] HEUEL S and ROHLING H. Pedestrian classification in automotive radar systems[C]. 2012 13th International Radar Symposium, Warsaw, Poland, 2012: 39–44. doi: [10.1109/IRS.2012.6233285](https://doi.org/10.1109/IRS.2012.6233285).
- [11] LANDGREBE D A. Signal Theory Methods in Multispectral Remote Sensing[M]. Hoboken, USA: Wiley, 2003. doi: [10.1002/0471723800](https://doi.org/10.1002/0471723800).
- [12] EL AKADI A, AMINE A, EL OUARDIGHI A E, *et al.* A two-stage gene selection scheme utilizing MRMR filter and GA wrapper[J]. *Knowledge and Information Systems*, 2011, 26(3): 487–500. doi: [10.1007/s10115-010-0288-x](https://doi.org/10.1007/s10115-010-0288-x).
- [13] TEKELI B, GURBUZ S Z, and YUKSEL M. Information-theoretic feature selection for human Micro-Doppler signature classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(5): 2749–2762. doi: [10.1109/TGRS.2015.2505409](https://doi.org/10.1109/TGRS.2015.2505409).
- [14] JOLLIFFE I T. Principal Component Analysis[M]. 2nd ed. New York, USA: Springer, 2002: 1–9.
- [15] WANG Zigeng, XIAO Xia, and RAJASEKARAN S. Novel and efficient randomized algorithms for feature selection[J]. *Big Data Mining and Analytics*, 2020, 3(3): 208–224. doi: [10.26599/BDMA.2020.9020005](https://doi.org/10.26599/BDMA.2020.9020005).
- [16] GÜRBÜZ S Z, TEKELI B, KARABACAK C, *et al.* Feature selection for classification of human Micro-Doppler[C]. IEEE International Conference on Microwaves, Communications, Antennas and Electronic Systems, Tel Aviv, Israel, 2013: 1–5. doi: [10.1109/COMCAS.2013.6685318](https://doi.org/10.1109/COMCAS.2013.6685318).
- [17] WU Yanwei, JIANG Mian, PEI Xiaoshuai, *et al.* Feature selection and decision fusion methods in target recognition[C]. IET International Radar Conference, Chongqing, China, 2021: 687–690. doi: [10.1049/icp.2021.0789](https://doi.org/10.1049/icp.2021.0789).
- [18] XIAO Peng, WANG Zigeng, and RAJASEKARAN S. Novel speedup techniques for parallel singular value decomposition[C]. 2018 IEEE 20th International Conference on High Performance Computing and Communications; IEEE 16th International Conference on Smart City; IEEE 4th International Conference on Data Science and Systems, Exeter, UK, 2018: 188–195. doi: [10.1109/HPCC/SmartCity/DSS.2018.00056](https://doi.org/10.1109/HPCC/SmartCity/DSS.2018.00056).
- [19] CHANDRASHEKAR G and SAHIN F. A survey on feature selection methods[J]. *Computers & Electrical Engineering*, 2014, 40(1): 16–28. doi: [10.1016/j.compeleceng.2013.11.024](https://doi.org/10.1016/j.compeleceng.2013.11.024).
- [20] WANG Yunyan, ZHUO Tong, ZHANG Yu, *et al.* Hierarchical polarimetric SAR image classification based on feature selection and Genetic algorithm[C]. 2014 12th International Conference on Signal Processing (ICSP), Hangzhou, China, 2014: 764–768. doi: [10.1109/ICOSP.2014.7015107](https://doi.org/10.1109/ICOSP.2014.7015107).
- [21] BHANU B and LIN Yingqiang. Genetic algorithm based feature selection for target detection in SAR images[J]. *Image and Vision Computing*, 2003, 21(7): 591–608. doi: [10.1016/S0262-8856\(03\)00057-X](https://doi.org/10.1016/S0262-8856(03)00057-X).
- [22] SENTHILNATH J, OMKAR S N, MANI V, *et al.* Multi-sensor satellite remote sensing images for flood assessment using swarm intelligence[C]. 2015 International Conference on Cognitive Computing and Information Processing, Noida, India, 2015: 1–5. doi: [10.1109/CCIP.2015.7100706](https://doi.org/10.1109/CCIP.2015.7100706).
- [23] LIANG Kui, DAI Wei, and DU Rui. A feature selection method based on improved genetic algorithm[C]. 2020 Global Reliability and Prognostics and Health Management (PHM-Shanghai), Shanghai, China, 2020: 1–5. doi: [10.1109/PHM-Shanghai49105.2020.9281001](https://doi.org/10.1109/PHM-Shanghai49105.2020.9281001).
- [24] LI Yinghao, SHI Kai, QIAO Fuqiang, *et al.* A feature subset selection method based on the combination of PCA and

- improved GA[C]. 2020 2nd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI), Taiyuan, China, 2020: 191–194. doi: [10.1109/MLBDBI51377.2020.00042](https://doi.org/10.1109/MLBDBI51377.2020.00042).
- [25] YANG B S, HAN Tian, and YIN Zhongjun. Fault diagnosis system of induction motors using feature extraction, feature selection and classification algorithm[J]. *JSME International Journal Series C: Mechanical Systems, Machine Elements and Manufacturing*, 2006, 49(3): 734–741. doi: [10.1299/jsmec.49.734](https://doi.org/10.1299/jsmec.49.734).
- [26] LIU Ming, DING Xiangqian, YU Shusong, *et al.* Research on feature selection in near-infrared spectroscopy classification based on improved adaptive genetic algorithm combined with ReliefF[C]. 2017 9th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), Hangzhou, China, 2017: 403–406. doi: [10.1109/IHMSC.2017.202](https://doi.org/10.1109/IHMSC.2017.202).
- [27] YANG Jianyong and YAN Ruqiang. A multidimensional feature extraction and selection method for ECG arrhythmias classification[J]. *IEEE Sensors Journal*, 2021, 21(13): 14180–14190. doi: [10.1109/JSEN.2020.3047962](https://doi.org/10.1109/JSEN.2020.3047962).
- [28] THEJASWEE M, SRILAKSHMI P, KARUNA G, *et al.* Hybrid IG and GA based feature selection approach for text categorization[C]. 2020 4th International Conference on Electronics, Communication and Aerospace Technology (ICECA), Coimbatore, India, 2020, 1606–1613. doi: [10.1109/ICECA49313.2020.9297468](https://doi.org/10.1109/ICECA49313.2020.9297468).
- [29] DELON J, DESOLNEUX A, LISANI J L, *et al.* A nonparametric approach for histogram segmentation[J]. *IEEE Transactions on Image Processing*, 2007, 16(1): 253–261. doi: [10.1109/TIP.2006.884951](https://doi.org/10.1109/TIP.2006.884951).
- [30] OUAKNINE A, NEWSON A, REBUT J, *et al.* CARRADA dataset: Camera and automotive Radar with range- angle-Doppler annotations[C]. 2020 25th International Conference on Pattern Recognition (ICPR), Milan, Italy, 2021: 5068–5075. doi: [10.1109/ICPR48806.2021.9413181](https://doi.org/10.1109/ICPR48806.2021.9413181).
- [31] WHITLEY D. A genetic algorithm tutorial[J]. *Statistics and Computing*, 1994, 4(2): 65–85. doi: [10.1007/BF00175354](https://doi.org/10.1007/BF00175354).
- [32] SAITO T and REHMSMEIER M. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets[J]. *PLoS One*, 2015, 10(3): e0118432. doi: [10.1371/journal.pone.0118432](https://doi.org/10.1371/journal.pone.0118432).

作者简介

瓦其日体, 硕士生, 主要研究方向为毫米波雷达目标识别。

李 刚, 博士, 教授, 博士生导师, 主要研究方向为雷达信号处理、遥感、多源信息融合、数据驱动医疗健康等。

赵志纯, 博士, 副教授, 主要研究方向为雷达信号处理、时频分析、微动特征分析、雷达目标识别技术等。

则正华, 硕士生, 主要研究方向为毫米波雷达信号处理。

(责任编辑: 于青)