

基于语义引导层次化分类的雷达地面目标 HRRP识别方法

李阳^{1,2,3,4} 刘艺辰^{1,2,3,4} 张亮^{*1,2} 王彦华^{1,2,3,4,5}

- 北京理工大学雷达技术研究院, 北京 100081;
- 嵌入式实时信息处理技术北京市重点实验室, 北京 100081;
- CEMEE国家重点实验室电磁感知研究中心, 北京 100081;
- 北京理工大学重庆创新中心, 重庆 401135;
- 北京理工大学前沿技术研究院, 山东济南 250300)

摘要: 高分辨距离像(HRRP)反映了目标空间散射结构在雷达视线方向的投影,近年来被认为是地面目标识别的重要途径。现有的HRRP识别方法采用手工特征加传统机器学习分类器,均属于平面分类方法,即采用统一标准不加区别的优选特征并单次决策最终类别。然而该方法在实际应用中面临种类繁多、数据不平衡、HRRP姿态敏感性等诸多问题,难以获取最佳的应用效果。层次化方法采取分而治之的思想,将一个复杂的细粒度识别任务拆解为多个简单的识别子任务。本文采用层次化识别的思路,提出了一种基于语义引导层次化分类的雷达地面目标识别方法。该方法以联合语义和数据构建的树形结构将一个复杂的细粒度识别任务拆解为多个简单的识别子任务,并针对每一个识别子任务匹配一套优选特征集和一个局部分类器。本方法在仿真数据和实测数据上完成了验证。实验结果表明了本文方法处理地面目标识别任务的有效性。

关键词: 雷达目标识别; 高分辨距离像; 层次化分类

中图分类号: TN959.1 **文献标识码:** A **DOI:** 10.16798/j.issn.1003-0530.2024.01.008

引用格式: 李阳,刘艺辰,张亮,等. 基于语义引导层次化分类的雷达地面目标HRRP识别方法[J]. 信号处理,2024, 40(1): 126-137. DOI: 10.16798/j.issn.1003-0530.2024.01.008.

Reference format: LI Yang, LIU Yichen, ZHANG Liang, et al. Semantic knowledge guided hierarchical classification for radar ground target HRRP recognition[J]. Journal of Signal Processing, 2024, 40(1): 126-137. DOI: 10.16798/j.issn.1003-0530.2024.01.008.

Semantic Knowledge Guided Hierarchical Classification for Radar Ground Target HRRP Recognition

LI Yang^{1,2,3,4} LIU Yichen^{1,2,3,4} ZHANG Liang^{*1,2} WANG Yanhua^{1,2,3,4,5}

- Radar Technology Research Institute, Beijing Institute of Technology, Beijing 100081, China;
- Beijing Key Laboratory of Embedded Real-time Information Processing Technology, Beijing 100081, China;
- The Electromagnetic Sensing Research Center of CEMEE State Key Laboratory, Beijing Institute of Technology, Beijing 100081, China;
- Chongqing Innovation Center, Beijing Institute of Technology, Chongqing 401135, China;
- The Advanced Technology Research Institute, Beijing Institute of Technology, Jinan, Shandong 250300, China)

收稿日期: 2023-09-28; 修回日期: 2023-12-25

*通信作者: 张亮 zhangliang@bit.edu.cn *Corresponding Author: ZHANG Liang, zhangliang@bit.edu.cn

基金项目: 国家自然科学基金(62388102);重庆市自然科学基金(cstc2020jcyj-msxmX0812);中国博士后科学基金(2023M730269)

Foundation Items: The National Natural Science Foundation of China (62388102); The Natural Science Foundation of Chongqing (cstc2020jcyj-msxmX0812); Postdoctoral Science Foundation of China (2023M730269)

Abstract: High-Resolution Range Profile (HRRP) is increasingly recognized as a critical method for ground target identification, reflecting the spatial scattering structure of targets along the radar line of sight. Traditional HRRP identification techniques typically employ hand-crafted features and conventional machine learning classifiers in a flat classification approach, applying a uniform set of preferred features and making a single decision on the final category. However, this approach faces significant challenges in practical applications due to complex target categories, data imbalance, and sensitivity to HRRP postures, often resulting in suboptimal performance. To address these issues, this paper introduces a novel method for radar ground target identification based on a semantically guided hierarchical classification approach. This method adopts a divide-and-conquer strategy, effectively breaking down a complex, fine-grained identification task into multiple, more manageable sub-tasks. It employs a tree structure, jointly constructed using semantic and data-driven information. Each sub-task is matched with a tailored set of optimal features and a local classifier, ensuring a more nuanced and effective approach to target identification. The proposed method has been thoroughly tested and validated using both simulated and real-world data. The experimental results demonstrate the efficacy of this approach in handling ground target identification tasks, significantly enhancing accuracy and robustness compared to traditional methods. This semantically-informed hierarchical approach opens new avenues for advanced ground target identification, providing a robust framework for tackling the inherent complexities in HRRP data.

Key words: radar automatic target recognition (RATR); high resolution range profile (HRRP); hierarchical classification

1 引言

自动目标识别技术是雷达对地探测的一项重要技术支撑手段^[1]。近年来,通常采用高分辨技术获取目标精细电磁散射信息,从而改善识别性能。现有手段可获取一维高分辨距离像(High Resolution Range Profile, HRRP)和合成孔径雷达图像(Synthetic Aperture Radar, SAR)^[2]。由于 SAR 成像过程对运动轨迹、积累时间等有严格要求,成像质量受运动误差影响大,而且处理过程对计算和存储能力要求高,导致实际应用受到诸多限制。因此,基于 HRRP 的目标识别技术在对地探测中拥有重要应用价值。

为提升 HRRP 地面识别性能,现有研究工作可分为两大类:提取手工特征并输入传统机器学习分类器和基于深度学习的识别方法^[3-6]。尽管上述方法均在某些场景下表现出色,但受限于实际应用场景以下几方面因素:目标类别繁多,场景中存在各种车辆目标或者自然干扰;采集姿态不完备,难以建立目标全姿态下的特征数据库;目标类别数量不平衡,不同目标的采集得到的回波样本量差异较大^[7]。因此,现有研究工作难以取得良好的应用性能。

现有 HRRP 识别方法通常采用平面决策机制,即采用统一标准不加区别的优选特征并单次决策最终类别。然而,平面决策机制难以在类别繁多且类别不平衡目标识别任务中决策目标的型号,而且平面决策机制难以同时捕捉区分相似型号目标的精细散射特性差异以及不同种类目标的显著散射

特性差异。

层次化分类被认为是类别繁多、类别不平衡数据集下实现型号辨识的有效手段^[8]。该方法通过树形层次组织多个局部分类器,处理不同的特征集,将一个复杂的细粒度识别任务拆解为多个分层次的简单识别子任务;每个子任务待处理的类别较少,更容易保证样本的平衡。此外,针对每个识别子任务,层次化分类方法可以对原始特征进行个性化优选与利用,从而挖掘目标特征中隐含的共性与个性规律。在此基础上,加以匹配适合识别子任务的分类器模型,以增强局部分类器的性能,从而提高层次化方法的准确性和鲁棒性。

尽管层次化分类在计算机视觉、文本分割领域取得良好效果^[9-13],但是将层次分类应用于 HRRP 识别依然存在以下难点问题:由于 HRRP 受采集姿态影响较大,层次分类的树形层次结构在自动化构建时,最终获取的类别特征表示也会有巨大差别,导致构建稳定性差的树形层次。

针对上述难点问题,本文提出了一种新的层次化分类方法——语义引导的层次化雷达目标识别方法。通过将语义信息引入树形层次结构的构建,改善了树形层次的稳定性,提高了层次化分类方法的识别性能。首先,考虑姿态敏感性,数据在类别标签的基础上,增加了姿态标签,并将各个标签之间的相似性关系量化为语义相似度指标。然后,将各个标签下的 HRRP 的相似性关系量化为数据相似度指标;随后,联合语义相似度指标与数据相似度指标,设计类别相似度指标,并依据该指标自动化的构建树形层次。

本文提出的树形层次构建方法带来了以下三点优势:(1)由于姿态与类别语义信息的约束,树形层次对数据的依赖性降低;(2)相似度高的细粒度类别聚集到同一树形节点,可看作是这些细粒度类别被打上了粗粒度标签,区分粗粒度标签的难度大大降低;(3)而在细粒度标签区分节点,可匹配关注精细差别的特征子集和分类器,提高识别精度。

2 相关工作

层次分类器是多分类器系统(MCS, Multi-classifier System)方法的一种^[14]。MCS方法根据特定的组合方式组织多个分类器并输出最终类别。典型的分类器融合方法分为串联、并联、层次化三种。该方法综合多个分类器的输出以获取互补信息,提高识别准确率。文献[15]中,Y. Li等提出了一个两阶段结构,首先识别跟踪车辆数据,再使用SVM分类器进一步分类。文献[16]中,Pilcher等则设计了一个结合三种分类器的非线性规则,提高了VV和HH极化范围的性能。文献[17]中,X. Yu等提出了一个融合三个分类器的系统,该系统在MSTAR数据集上的表现优于传统方法。这些MCS方法主要采用串联或并行的策略。然而,上述方法主要采用串联和并联的融合策略,较少考虑层次融合方式。

层次分类器常按照两种方式组织^[8]:1)树和2)有向无环图(DAG)。由于树形层次结构更为通用,本文以该结构作为组织方式。图1为树形层次结构示意图,其中灰色节点表示叶子节点,存储最终输出目标类别;白色节点分为“根节点”和中间节点,每个白色节点上存储了该节点的类别,与一个用以区分该节点的子节点类别的局部分类器。

层次化分类器的两大关键技术分别为树形层次结构构建和局部分类器训练^[8-19]。现有的树形层次构建方法包括基于先验语义信息的人工构建和

基于数据的自动化构建。基于先验语义信息人工构建方法是指基于领域专家认知的目标类别语义信息构建,其先验语义信息通常与识别任务需求相关。然而由于目标识别是基于特征空间进行的,该方法忽略了各类别之间的特征分布,因此识别性能受到限制。基于数据的自动化构建方法是通过计算不同类别数据在特征空间的相似度,然后利用聚类的方式递归的获取树形层次结构,尽可能地将数据相似度高的类别组织到同一节点基分类器完成分类,在现有的目标数据充足且完备时有较好的识别效果。然而,实际识别场景中,地面环境十分复杂,目标类别繁杂多样,难以对于各个目标类别获取充足完备的数据。基于数据的自动化构建方法存在不可控因素多、性能稳定性不足、对数据适应能力差等问题。针对上述问题,本文提出了一种语义知识引导的自动层次结构生成方法,由于增加了语义知识的约束,自动化构建方法对数据依赖性降低,且更稳定。

局部分类器训练环节,鉴于只有部分特征对分类具有决定性作用,研究者通常在模型训练前进行特征选择,旨在降低计算复杂度并增强分类的精确度。完成特征选择后,根据不同的子任务识别需求选择最合适的机器学习模型。例如,SVM在处理二分类问题上有着显著的优势,而深度学习模型在数据量充裕的精细分类任务上表现更为出色。

层次化分类器的一大核心挑战是差错传播问题^[3,13,19],即父节点分类错误会传播给子节点,影响整个分类系统的性能。针对这一问题,通常有两种改进策略:一是优化层次化分类器的层次结构,通过将相似的子节点聚集在同一父节点下,从而有效降低在每个父节点进行分类的难度。这种方法能够改善父节点的识别性能,因为每个父节点处理的子节点在特征上更为相似,从而降低了分类的复杂性。二是加入差错传播层,对层次化分类结果加以修正。本文采用第一种研究思路,在树形层次构建时,尽可能地将相似的子节点聚集到同一父节点,以提高整个层次化分类器的识别性能。

3 语义知识引导的层次化雷达目标识别方法

3.1 整体结构

图2展示了本文提出的HRRP目标识别方法的整体结构。整体结构包括树形层次构建模块、训练模块和测试模块三个部分组成。在树形层次构建




图1 树形层次结构示意图

Fig. 1 Diagram of tree hierarchy

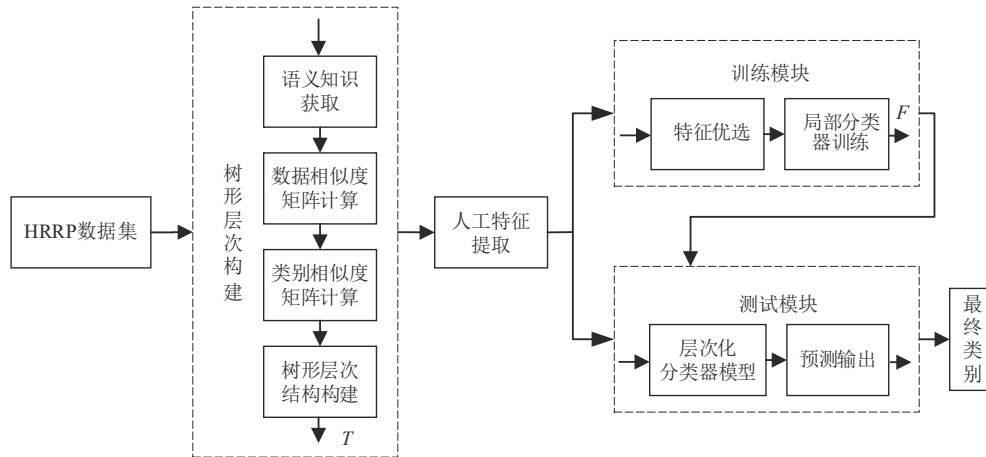


图 2 层次化 HRRP 目标识别整体框图

Fig. 2 The overall structure of the proposed model for HRRP target recognition

模块,首先获取 HRRP 数据集的语义知识,其次根据计算各类别 HRRP 数据的相似度关系,随后融合数据相似度矩阵与语义知识,计算得到类别相似度矩阵,最后基于类别相似度矩阵构建树形层次结构 T 。基于 HRRP 数据集提取人工特征,将特征样本集分为训练集和测试集。训练集输入训练模块,在树形层次结构 T 中的各个节点优选特征,并匹配局部分类器,训练各个局部分类器,得到分类器模型 F 。测试集输入测试模块,将各个局部分类器以树形层次组织成层次化分类器,层次化分类器预测输出测试样本的最终类别。下面将对本文方法进行详细介绍。

3.2 树形层次结构构建

3.2.1 语义知识提取

本节将领域专家感知到的类别之间的语义关系与采集姿态信息,量化为语义知识矩阵表示。这种方法为后续的树状层次构建添加了约束,从而避免了由于 HRRP 的姿态敏感性导致的类别节点的误分类。

语义知识通常与应用场景相关。本文的语义知识源于领域专家关于雷达目标识别任务的认知^[3],可以分为三个层次,以复杂地面环境车辆目标识别为例:第一层次:目标鉴别(Target discrimination),主要实现目标属性的判别,将车辆目标与各类地面干扰物进行区分;第二层次:目标分类(Target classification),主要实现目标种类的判定,例如运输车、工程车等;第三层次:目标辨识(Target identification),主要实现目标具体型号的确定。此外,考虑到 HRRP 的姿态敏感性,本文在上述三个层次上增加姿态信息,根据上述定义,本文构建了一个

具有 4 个层次的语义层次树,表示属性、种类、型号和姿态,如图 3 所示。

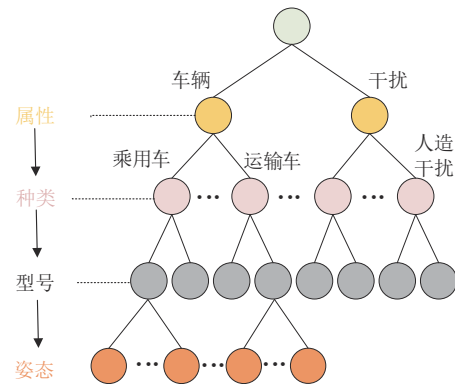


图 3 语义层次结构

Fig. 3 Semantic Tree Hierarchy

其次,将语义知识表示为语义相似度矩阵。本文依据节点在图 3 所示树形结构中的距离远近来判断不同标签的语义相似关系。两节点在树形结构中的距离越近,即从根节点出发,到达两节点路径的公共节点越多,说明两节点存储标签的语义相似度越大;两节点在树形结构中的距离越远,即从根节点出发,到达两节点路径的公共节点越少,语义相似度越小。任意两种标签之间的语义相似度在 $(0, 1]$ 之间。根据上述思路,对于类别 A 和类别 B,可将两者之间的语义相似度计算公式表示如下:

$$k_c(A, B) = \frac{\text{length}(\text{path}(A \cap B))}{\text{avg}(\text{length}(\text{path}(A), \text{length}(\text{path}(B)))} \quad (1)$$

其中, $\text{path}(A)$ 表示从根节点到包含有型号 A 的叶节点的路径, $\text{path}(A \cap B)$ 表示两条路径的公共节点, $\text{length}(\cdot)$ 表示路径的节点个数, $\text{avg}(\cdot)$ 表示路径节点

个数的平均值。假设训练数据包含 C 个类别, 则可获得一个对称的维数为 $C \times C$ 的语义相似度矩阵 \mathbf{K}_c 。

3.2.2 数据相似度

首先, 针对每个类别提取有效的特征表示。其中, 叶子节点的特征样本集即为该节点类别的特征样本集, 而其余节点的特征样本集为该节点相连子节点特征样本集的并集。本文采用主动采样算法^[20]设计典型性指标和多样性指标评估特征样本集中的所有特征样本, 搜索最具代表性的样本作为该类别的特征表示。典型性指标用于评估特征样本集中每个样本的代表性程度。具体来说, 这个指标反映了一个特定样本与同类其他样本的相似性。在特征样本集中, 典型性指标较高的样本表明它与该类别中的多数样本具有相似的特征, 从而可以被认为是这一类别的典型代表。多样性指标用于量化特征样本集内部样本之间的差异程度。这一指标帮助本文理解在给定类别内样本的变异性与多样性水平。如果一个样本的多样性指标高, 这通常说明该样本在所考虑的特征集合中与其他样本有着较大的差异性。

假设类别 A 的特征样本集 X 包含 M 条样本, 可表示为 $X = \{\mathbf{x}_i, i=1, \dots, M\}$, \mathbf{x}_i 表示 X 中一条样本的特征向量。 \mathbf{x}_i 的典型性指标 $R(\mathbf{x}_i)$ 与多样性指标 $D(\mathbf{x}_i)$ 的定义如下式所示。

$$R(\mathbf{x}_i) = \frac{1}{|N_i|} \sum_{j \in N_i} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|_2^2 / 2\delta_r^2)$$

$$D(\mathbf{x}_i) = \min_{\mathbf{x}_j \in X} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|_2^2 / 2\delta_r^2) \quad (2)$$

其中, N_i 为 \mathbf{x}_i 邻近样本集, δ_r 为高斯核带宽, $|N_i|$ 代表的是这个邻近样本集中样本的总数。依据典型性指标与多样性指标对 X 中的所有样本进行评估, 输出满足以下条件的样本:

$$\arg \max (R(\mathbf{x}_i) + D(\mathbf{x}_i)) \quad (3)$$

将该样本作为类别 A 的特征表示 $r(A)$ 。依据上述过程, 分别计算各类别的特征表示。

随后, 计算各类别样本数据的相似关系。本文依据不同类别在特征空间的距离来判定不同类别的数据相似关系。两类别在特征空间的距离用两类别的特征表示向量之间的欧式距离来表示。若两类别的特征表示向量之间的欧式距离越小, 则两类别之间的数据相似度越大; 反之, 若两类别的特征表示向量之间的欧式距离越大, 则两类别之间的数据相似度越小。对于类别 A 和类别 B , 两者之间的数据相似度计算公式如下:

$$k_d(A, B) = \frac{1}{1 + d(r(A), r(B))} \quad (4)$$

其中, $d(\cdot)$ 表示欧式距离, $r(A)$ 为类别 A 的特征表示, $r(B)$ 为类别 B 的特征表示。

假设训练数据包含 C 个类别, 则可获得一个对称的维数为 $C \times C$ 的数据相似度矩阵 \mathbf{K}_d 。

3.2.3 类别相似度

本文采用多核学习方法^[21], 融合语义相似度矩阵与数据相似度矩阵获取类别相似度度量指标。多核学习的核心目的是探索基核矩阵的最适合的结合策略, 实现矩阵的有效融合。在基核矩阵的结合方法上, 有线性和非线性两种选择。由于非线性结合在计算上较为复杂, 并且其可解释性不佳, 因此本文选择使用线性结合。具体的融合步骤如下: 假设共有 C 个类别, 可获得 $C \times C$ 的语义相似度矩阵 \mathbf{K}_c 与数据相似度矩阵 \mathbf{K}_d 。对 \mathbf{K}_c 和 \mathbf{K}_d 进行归一化处理得到 \mathbf{K}'_c 和 \mathbf{K}'_d , 定义优化目标函数为:

$$\min_w \|I - w_1 \mathbf{K}'_c - w_2 \mathbf{K}'_d\|_F^2, \quad \text{s.t.} \sum_{m=1}^2 w_m = 1 \quad (5)$$

其中 I 为单位矩阵, w_1, w_2 为常数系数。学习上述优化目标函数可得到组合系数 w_1 和 w_2 , 用于计算融合相似度度量矩阵。选择这个优化目标是为了让融合后的核心矩阵尽量靠近单位矩阵, 其目的主要有两点: 首先, 单位矩阵的对角线上的元素值为 1, 其他位置的元素值为 0, 这确保了同一类别内部的相似度最大, 而不同类别之间的相似度最小; 其次, 由于在目标函数中对权重的总和有限制, 这意味着融合后的相似度所描述的类别关系与融合前的每个基核矩阵所描述的类别关系是一致的。

最后, 计算类别相似度矩阵 \mathbf{K}_s :

$$\mathbf{K}_s = w_1 \mathbf{K}'_c + w_2 \mathbf{K}'_d \quad (6)$$

3.2.4 自动化层次构建

采用 3.2.3 节得到的类别相似度矩阵 \mathbf{K}_s , 通过 Kmeans 聚类算法^[22]自适应构建树形层次结构 T 。首先, 将类别相似度矩阵转化为距离矩阵; 其次, 随机选择 K 个数据点作为初始聚类中心, 根据距离矩阵为每个数据点分配最近的中心; 随后, 重新计算每个聚类的中心点, 上述过程会重复, 直到聚类中心不再发生显著变化或达到预定的迭代次数。Kmeans 的目的是最小化每个数据点到其分配的中心的距离之和, 以此达到数据的聚类效果。图 4 给出了树形层次结构构建的流程图。其中, 树形结构中的灰色节点表示叶子节点, 白色节点分为“根节点”和中间节点。中间节点中的字符指代该节点存

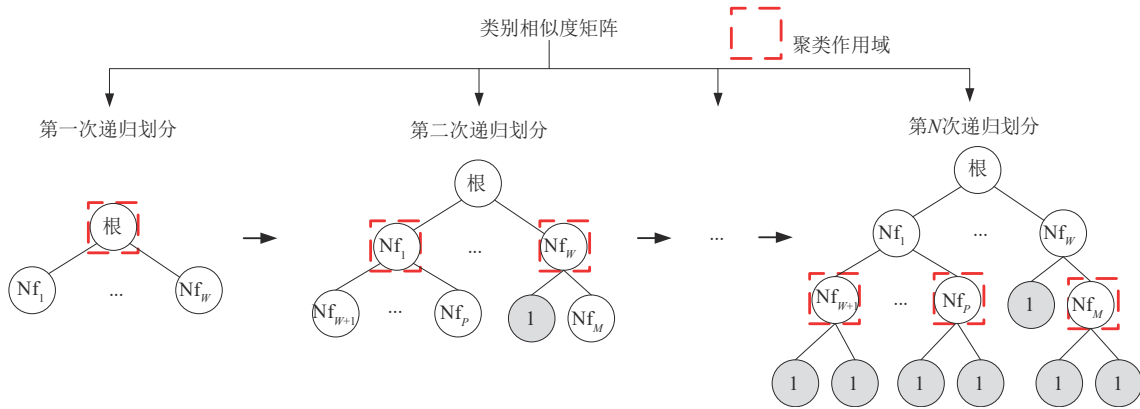


图 4 树形层次结构构建流程

Fig. 4 Tree hierarchy construction process

储的类别个数,表示为 $Nf_i \{i=1, 2, 3, \dots, W, \dots, P, \dots, M\}$ 。叶子节点只存储单个类别,所以节点中的数字为“1”。

对于图 4 展示的构建流程的详细说明如下:

(1)采用类别相似度矩阵 K_s ,基于 Kmeans 算法可将父节点 f 中包含的所有目标类别集合 J_f 聚类为 Q 个子集合 $Jc_i \{i=1, 2, 3, \dots, Q\}$,并将各个子集合 Jc_i 存储到父节点相连的子节点 $c_i \{i=1, 2, 3, \dots, Q\}$ 。层次结构父子节点关系示意图如图 5 所示。为了优选聚类子集合个数 Q ,本文选用轮廓系数作为聚类评估的指标,采用轮廓系数达到最高值时对应的子集合个数作为 Q 。




图 5 层次结构父子节点关系示意图

Fig. 5 Hierarchical structure parent-child relationship diagram

(2)从“根”节点开始执行上述划分过程,基于类别相似度矩阵 K_s 聚类得到多个子集合,并存储到相连子节点;然后对所有的子集合递归执行上述划分过程,每次划分后,所得到的子集合中的标签数目更少,直至所有划分的子集合中仅有一个目标标签,将单个目标标签存储到叶子节点。以图 4 为例,从“根”节点开始,每次递归划分过程都仅对红色虚线框圈住的节点执行操作,在第 N 次递归划分过程

后,生成的节点只存储了单个标签,最终完成树形层次结构的构建,并将所构建的树形层次记作 T 。

3.3 训练过程

如图 2 中训练模块所示,首先,将多个基分类器按照 3.2 节所构建的树形层次 T 组织。如图 1 所示,白色节点既存储了该节点的训练数据,又存储了用于区分其子节点类别的局部分类器,灰色节点仅仅存储了其最终的目标类别。

其次,在各个节点的局部分类器中输入训练数据,根据训练数据优选特征子集。本文采用了 Sklearn 中提供的基于模型的特征选择 (Model-based feature selection) 方法^[23]。此处不再详细赘述。

随后,分别将各分类节点的优选特征子集输入对应节点存储的局部分类器模型,在各局部分类器中训练,训练参数模型记作 F 。不同的识别子任务将匹配不同的机器学习算法模型。各个分类节点所设置的分类器可以选用 SVM 等常用机器学习模型。

3.4 测试阶段

输入样本 u 到训练参数模型 F ;从根节点开始,沿着从根节点到叶子节点的路径进行搜索,以此确定最终输出类别。具体来讲,当测试样本经过节点 v 时,节点 v 存储的局部分类器将决定测试样本应该经过的下一个节点。如果下一个节点是叶子节点,则该叶子节点的类别就是测试样本的分类结果。但如果下一个节点是非叶子节点,那么测试样本将继续由该节点存储的局部分类器来决定其下一个要经过的节点,上述过程会持续,直到测试样本到达叶子节点为止。

4 实验分析

4.1 实验数据

在本实验中,本文采用了一台双极化宽带雷达进行数据收集。该雷达发射水平线性极化(H)信号,并同时接收水平(H)和垂直(V)正交极化信号。该雷达系统工作在W频段范围内,采用步进频率线性频率调制信号,具有1250 MHz的合成带宽,从而生成高分辨率目标的HRRP。实验数据集包含了2种干扰和8种车辆。其中,干扰物包括变电箱和高压塔。车辆包括5种乘用车、3种运输车辆。数据集中车辆目标极化HRRP数据采集自迎头、左/右正侧、尾追、左/右前斜和左/右后斜8种不同姿态,图6以卡车目标为例对其进行了展示。表1给出了各个目标的训练样本与测试样本说明,该数据集存在严重的样本类别不平衡问题,训练样本数目最小的类别SUV只有1880个样本,而训练样本数目最大的类别皮卡车包含104431个样本。

4.2 实验参数设置

基于HRRP实测数据集,本文提取了36个人工特征^[24-26],表2给出了所提特征的说明。

随后,本文在各个节点利用交叉验证方法比较SVM、决策树、多层感知机^[27]等常用分类器的识别性能,优选性能最优的分类模型作为节点的局部分类器。表3给出了本文选用的常用分类器,以及交

叉验证时的调参范围。

表4展示了为各个节点优选的局部分类器的参数配置。由此可见,由于每个节点所要处理的识别子任务有所区别,因此根据各自的特性选择的局部分类器也存在差异。此外,SVM更适用于二分类任务,而决策树更适用于区分干扰物和车辆目标的种类,多层感知机则更适用于精细化识别任务,即区分同一种类目标的具体型号。

4.3 实验结果分析

4.3.1 可视化结果分析

训练特征数据集的可视化效果如图7所示,训练特征数据集的分布表现得相当复杂。各类目标之间的边界并不明显,在特征空间中高度重叠,为目标识别带来了更大的挑战。

本文依据关于雷达目标识别任务的认知而定义的语义知识如下:第一层实现目标鉴别,区分车辆目标和地面干扰。第二层实现目标分类,区分运输车 and 乘用车。第三层实现目标辨识,区分多种型号的运输车,厢式货车、货车、大巴车;还有多种型号的乘用车,SUV、敞篷车、MPV等;以及多种地面干扰,变电箱和高压塔。依据上述语义知识,按照3.2.1构建的语义相似度矩阵如图8所示。

融合语义相似度与数据相似度矩阵,构建的类别相似度矩阵如图9所示。

针对待分类数据,依据该类别相似度矩阵,按

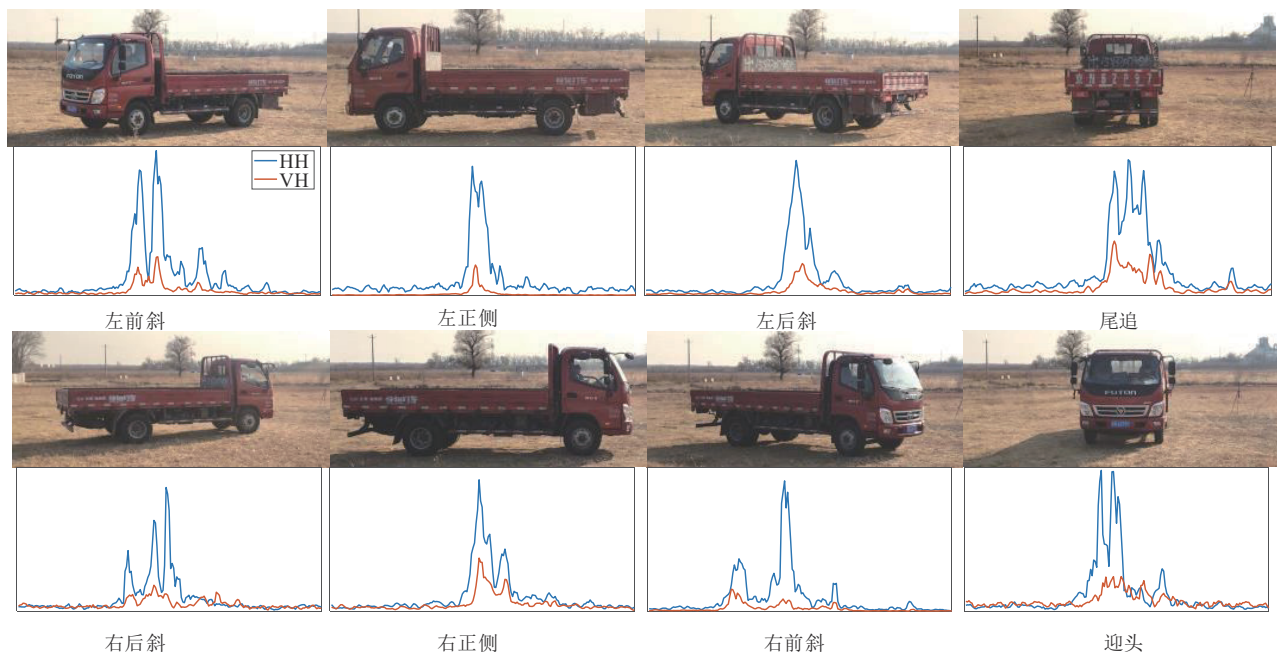


图6 各个采集姿态下卡车的HRRP

Fig. 6 HRRP of the truck under various acquisition poses

表 1 数据集说明

Tab. 1 Dataset description

类别	类型	型号	训练样本	测试样本	样本总数	
车辆目标		SUV	1880	808	2688	
		轿车	16831	7240	24071	
	乘用车	敞篷车	60278	26966	87244	
		MPV	37071	16013	53084	
		皮卡车	104431	45080	149511	
		厢式货车	5000	2150	7150	
	运输车	大巴车	28368	12155	40523	
		货车	34959	14973	49932	
	小计			288818	125385	414203
	干扰	人造建筑干扰	高压塔	5000	2150	7150
变电站			5000	2150	7150	
小计			10000	4300	14300	
合计			298818	129685	457781	

表 2 人工特征说明

Tab. 2 Handcrafted Feature description

特征标号	特征含义
1~3	不同阈值下的峰值点个数
4~6	不同阈值下首尾峰值点之间的长度
7~8	不同阈值下的峰值长度比
9	谷值数量
10	质心
11~12	距远边缘和近边缘的最大峰值距离
13	峰值能量积累
14	稀疏度
15	最大峰值与第二大峰值的比率
16~17	对比度
18	结构比
19~20	对称性和分散性
21	去尺度特征
22	波动特征
23~25	H/ α 分解特征
26~28	基本散射机制特征
29~33	极化不变特征
34~36	Krogager 分解特征

照 3.2.4 节方法构建树形层次。所构建的树形层次如图 10(b)所示。此外,为了方便后续表达,本文用图 10(b)中的各个分类节点上的数字用以指代该节

表 3 各分类器调参范围

Tab. 3 Parameter Tuning Range for Each Classifier

	SVM	决策树	多层感知机
固定参数	核函数类型: 高斯核		激活函数:tanh; 隐层数:3
调优参数	惩罚参数: (5,1,15)	最大深度: (2,1,12)	隐层神经元个 数:(4,2,24)
最终优选 参数	惩罚参数:10	最大深度:6	隐层神经元个 数:10

表 4 局部分类器参数设置

Tab. 4 Local classifier parameter settings & recognition results comparison

分类器类型	参数设置	分类节点
支持向量机	核函数类型:高斯核;惩罚参数:10	'1'、'2'
决策树	最大深度:6	'3'、'4'
多层感知机	激活函数:tanh;隐层神经元个数:10;隐层数:3.	'5'、'6'、'7'

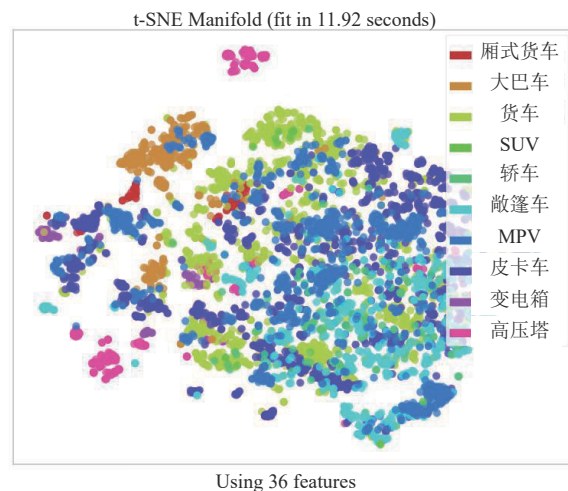


图 7 训练特征数据集 t-SNE 可视化结果

Fig. 7 T-SNE visualization results of the training feature dataset

点。由于各个类别下的姿态标签较多,且由于增加了语义约束,利用本文方法构建的同一类别的各个姿态标签依然被划分为同一父节点下分类,因此图 10并未展示姿态标签。对比图 10(a)和(b),在语义树形层次的基础上,本文的方法对乘用车节点进行了进一步的划分。划分后,乘用车 A 和乘用车 B 节点待分类的数据类别更少、区分度更高,缓解了类别不平衡问题。

厢式货车	货车	大巴车	SUV	敞篷车	MPV	皮卡车	轿车	变电站	高压塔
厢式货车	1	2/3	2/3	1/3	1/3	1/3	1/3	0	0
货车	2/3	1	2/3	1/3	1/3	1/3	1/3	0	0
大巴车	2/3	2/3	1	1/3	1/3	1/3	1/3	0	0
SUV	1/3	1/3	1/3	1	2/3	2/3	2/3	0	0
敞篷车	1/3	1/3	1/3	2/3	1	2/3	2/3	0	0
MPV	1/3	1/3	1/3	2/3	2/3	1	2/3	0	0
皮卡车	1/3	1/3	1/3	2/3	2/3	2/3	1	0	0
轿车	1/3	1/3	1/3	2/3	2/3	2/3	2/3	0	0
变电站	0	0	0	0	0	0	0	1	1/2
高压塔	0	0	0	0	0	0	0	1/2	1

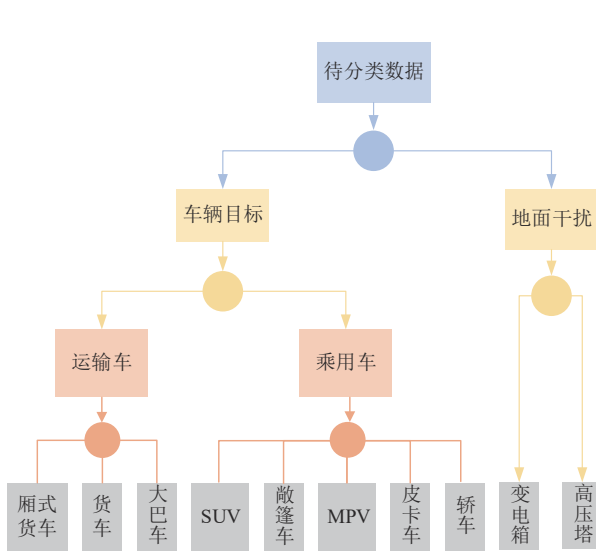
图8 语义相似度矩阵构建结果

Fig. 8 Results of Semantic Similarity Matrix

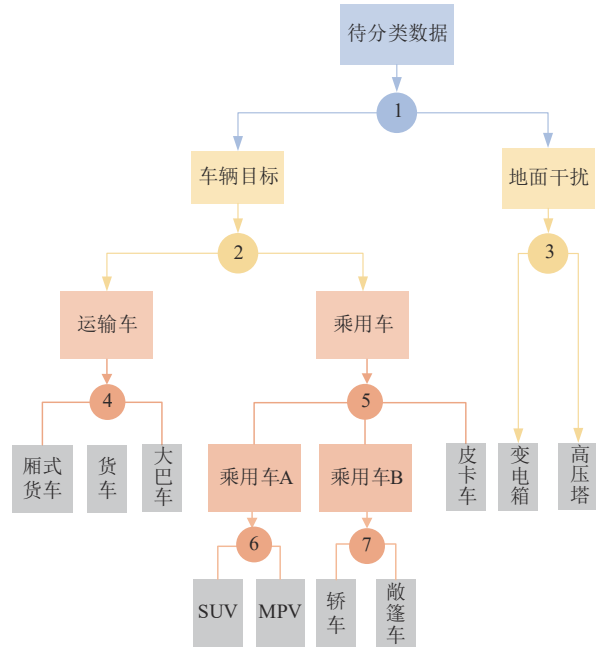
厢式货车	货车	大巴车	SUV	敞篷车	MPV	皮卡车	轿车	变电站	高压塔
厢式货车	1	0.20	0.48	0.04	0.05	0.08	0.07	0.08	0
货车	0.20	1	0.27	0.03	0.05	0.05	0.05	0.08	0
大巴车	0.48	0.27	1	0.05	0.03	0.03	0.03	0.03	0
SUV	0.04	0.03	0.05	1	0.57	0.49	0.29	0.41	0
敞篷车	0.05	0.05	0.03	0.57	1	0.60	0.21	0.52	0
MPV	0.08	0.05	0.03	0.49	0.60	1	0.20	0.44	0
皮卡车	0.07	0.05	0.03	0.29	0.21	0.20	1	0.23	0
轿车	0.08	0.08	0.03	0.41	0.52	0.44	0.23	1	0
变电站	0	0	0	0	0	0	0	0	1
高压塔	0	0	0	0	0	0	0	0.51	1

图9 类别相似度矩阵构建结果

Fig. 9 Results of Category Similarity Matrix



(a) 语义树形层次



(b) 本文方法树形层次

图10 语义树形层次与本文方法构建的树形层次结果比较

Fig. 10 Comparison between the semantic tree hierarchy and the tree hierarchy constructed by this study

图11展现了各个节点上特征的可视化效果。观察可得,各节点的任务区分难度已明显降低。此外,层次化方法还为本文提供了一种更为直观的方式来理解和解释数据的内在结构和相似性。

4.3.2 识别性能比较

首先,开展消融实验验证本文所构建的树形层次的有效性。结果如表5所示,三种方法的不同之处在于其树形层次结构。其中,Hier-Sem是依据图10(a)中语义层次组织形成的层次分类器;Hier-Data是依据HRRP数据自动化构建的树形层次组织形成的层次分类器。表5采用识别率作为评估各

方法识别性能的指标。识别率由预测正确的样本比上所有样本计算得到的。表5中各个方法的第一列表示种类识别率,即运输车、乘用车、干扰等类别标签的识别率。第二列表示型号识别率,即T1、T2、T3等型号标签的识别率。而最后一行的识别率是由测试集所有预测正确的样本比上测试集所有样本计算得到的。分析表5中结果可得:本文方法优于仅依据语义层次或者数据相似度组织的层次化分类器,这说明了本文在层次结构构建上的有效性,本文方法不仅考虑了类别间的语义关系,还有效地融合了数据特性,从而实现了更精准的分类结果。

的、更易于管理的子任务,从而实现了更高的识别精度和效率。

(2)虽然深度学习方法在一些方面优于传统的分类器方法,但在本次实验中,其识别结果却不如层次分类方法。这可能是由于深度学习方法在处理种类繁多、类别不平衡的型号辨识识别任务时,还需要更精细的特征提取和网络结构优化。

5 结论

针对地面目标识别应用需求,本文采用层次化识别的思路,提出了一种基于语义引导层次化分类的雷达地面目标识别方法。具体而言,本文所提出的层次分类框架关注树形层次构建。在树形层次构建环节,同时考虑了不同类别的HRRP和语义之间的相似关系,并设计相似度量指标。随后,利用聚类算法根据相似度量指标自动化的构建树形层次,使得相似度高的细粒度类别聚集到同一树形节点,可看作是这些细粒度类别被打上了粗粒度标签,任务区分难度进一步降低。本方法在实测数据和仿真数据上完成了验证。实验结果表明了本文方法处理细粒度识别任务的有效性。

未来围绕层次化分类的研究可从两方面进行:一方面,通过分析手工特征的物理含义,为特定的分类任务提供更加准确和有针对性的特征选择方法;另一方面,将层次分类方法与深度学习网络相结合,利用深度学习的强大学习能力,进一步提升细粒度识别的效率和精确度。

参考文献

- [1] 周云. 基于高分辨距离像的雷达目标识别研究[D]. 成都: 电子科技大学, 2016.
ZHOU Yun. Research on radar target recognition based on high resolution range profile[D]. Chengdu: University of Electronic Science and Technology of China, 2016. (in Chinese)
- [2] 刘宏伟, 杜兰, 袁莉, 等. 雷达高分辨距离像目标识别研究进展[J]. 电子与信息学报, 2005, 27(8): 1328-1334.
LIU Hongwei, DU Lan, YUAN Li, et al. Progress in radar automatic target recognition based on high range resolution profile[J]. Journal of Electronics and Information Technology, 2005, 27(8): 1328-1334. (in Chinese)
- [3] LI Long, LIU Zheng, LI Tao. Radar high resolution range profile recognition via multi-SV method[J]. Journal of Systems Engineering and Electronics, 2017, 28(5): 879-889.
- [4] 肖永生, 黄丽贞, 朱劼昊, 等. 最大间隔核优化的雷达目标识别新方法[J]. 信号处理, 2014, 30(7): 783-788.
XIAO Yongsheng, HUANG Lizhen, ZHU Jiehao, et al. A new radar target recognition method of the maximal margin kernel optimization [J]. Journal of Signal Processing, 2014, 30(7): 783-788. (in Chinese)
- [5] LIU Xiaodan, WANG Li, BAI Xueru. End-to-end radar HRRP target recognition based on integrated denoising and recognition network[J]. Remote Sensing, 2022, 14(20): 5254.
- [6] 郭宇. 基于高分辨距离像的支持向量数据描述目标识别算法研究[D]. 长沙: 国防科技大学, 2018.
GUO Yu. Research on support vector data description for HRRP-based target recognition[D]. Changsha: National University of Defense Technology, 2018. (in Chinese)
- [7] 郭鹏程, 王晶晶, 杨龙顺. 雷达地面目标识别技术现状与展望[J]. 航空兵器, 2022, 29(2): 1-12.
GUO Pengcheng, WANG Jingjing, YANG Longshun. Status and prospects of radar ground target recognition technology [J]. Aero Weaponry, 2022, 29(2): 1-12. (in Chinese)
- [8] 陆彦婷, 陆建峰, 杨静宇. 层次分类方法综述[J]. 模式识别与人工智能, 2013, 26(12): 1130-1139.
LU Yanting, LU Jianfeng, YANG Jingyu. A survey of hierarchical classification methods[J]. Pattern Recognition and Artificial Intelligence, 2013, 26(12): 1130-1139. (in Chinese)
- [9] NAIK A, RANGWALA H. Inconsistent node flattening for improving top-down hierarchical classification[C]//2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA). Montreal, QC, Canada. IEEE, 2016: 379-388.
- [10] LU Yu, HUANG Xudong, LIU Huaping, et al. Hierarchical classification for complexity reduction in HEVC inter coding[J]. IEEE Access, 2020, 8: 41690-41704.
- [11] REZAEI Z, ESLAMI B, AMINI M A, et al. Hierarchical three-module method of text classification in web big data[C]//2020 6th International Conference on Web Research (ICWR). Tehran, Iran. IEEE, 2020: 58-65.
- [12] WANG Leiguang, DAI Qinling, XU Qizhi, et al. Constructing hierarchical segmentation tree for feature extraction and land cover classification of high resolution MS imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(5): 1946-1961.
- [13] SILLA C N Jr, FREITAS A A. A survey of hierarchical classification across different application domains [J]. Data Mining and Knowledge Discovery, 2011, 22(1):

- 31-72.
- [14] DU Peijun, XIA Junshi, ZHANG Wei, et al. Multiple classifier system for remote sensing image classification: A review[J]. *Sensors*, 2012, 12(4): 4764-4792.
- [15] LI Yanbing, DU Lan, LIU Hongwei. Hierarchical classification of moving vehicles based on empirical mode decomposition of micro-Doppler signatures [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(5): 3001-3013.
- [16] PILCHER C M, KHOTANZAD A. Maritime ATR using classifier combination and high resolution range profiles [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2011, 47(4): 2558-2573.
- [17] YU Xin, LI Yukuan, JIAO L C. SAR automatic target recognition based on classifiers fusion[C]//2011 International Workshop on Multi-Platform/Multi-Sensor Remote Sensing and Mapping. Xiamen, China. IEEE, 2011: 1-5.
- [18] WANG Zhen, ZHANG Liqiang, FANG Tian, et al. A multiscale and hierarchical feature extraction method for terrestrial laser scanning point cloud classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(5): 2409-2425.
- [19] WANG Xiaolin, ZHAO Hai, LU Baoliang. A meta-top-down method for large-scale hierarchical classification [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2014, 26(3): 500-513.
- [20] 郑昱. 面向大规模图像分类的层次化多任务学习算法研究[D]. 西安: 西安电子科技大学, 2017.
ZHENG Yu. Study on hierarchical multi-task learning algorithms for large-scale image classification[D]. Xi'an: Xidian University, 2017. (in Chinese)
- [21] 史亚. 多核学习算法与应用研究[D]. 西安: 西安电子科技大学, 2015.
SHI Ya. Research on multiple kernel learning algorithms and their applications [D]. Xi'an: Xidian University, 2015. (in Chinese)
- [22] 王千, 王成, 冯振元, 等. K-means 聚类算法研究综述 [J]. *电子设计工程*, 2012, 20(7): 21-24.
WANG Qian, WANG Cheng, FENG Zhenyuan, et al. Review of K-means clustering algorithm [J]. *Electronic Design Engineering*, 2012, 20(7): 21-24. (in Chinese)
- [23] PILNENSKIY N, SMETANNIKOV I. Feature selection algorithms as one of the python data analytical tools[J]. *Future Internet*, 2020, 12(3): 54.
- [24] DU Lan, LIU Hongwei, BAO Zheng, et al. Radar automatic target recognition based on feature extraction for complex HRRP[J]. *Science in China Series F: Information Sciences*, 2008, 51(8): 1138-1153.
- [25] KIM K T, SEO D K, KIM H T. Efficient radar target recognition using the MUSIC algorithm and invariant features[J]. *IEEE Transactions on Antennas and Propagation*, 2002, 50(3): 325-337.
- [26] 王雪松. 雷达极化技术研究现状与展望[J]. *雷达学报*, 2016, 5(2): 119-131.
WANG Xuesong. Status and prospects of radar polarimetry techniques [J]. *Journal of Radars*, 2016, 5(2): 119-131. (in Chinese)
- [27] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
ZHOU Zhihua. *Machine Learning* [M]. Beijing: Tsinghua University Press, 2016. (in Chinese)
- [28] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. 2014: arXiv: 1409.1556. <http://arxiv.org/abs/1409.1556>.
- [29] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.

作者简介



李 阳 男, 1979 年生, 辽宁人。北京理工大学信息与电子学院研究员, 主要研究方向为宽带雷达系统、雷达信号处理。
E-mail: bit_liyang@bit.edu.cn



刘艺辰 女, 1998 年生, 河南人。北京理工大学雷达技术研究院博士研究生, 主要研究方向为雷达自动目标识别。
E-mail: liupeiyulucky@163.com



张 亮 男, 1993 年生, 内蒙古人。北京理工大学雷达技术研究院博士后, 主要研究方向为雷达极化信息处理、雷达自动目标识别。
E-mail: zhangliang@bit.edu.cn



王彦华 男, 1984 年生, 河南人。北京理工大学信息与电子学院副教授, 主要研究方向为雷达自动目标识别、高分辨雷达信号处理。
E-mail: wyhlucky@bit.edu.cn

(责任编辑: 边熙淳)