

doi: 10.7690/bgzdh.2025.11.005

# 基于机器学习的雷达目标识别研究分析综述

何永华<sup>1</sup>, 郭钱湧<sup>2</sup>, 吴鹏<sup>2</sup>, 桑鑫<sup>3</sup>

(1. 航天工程大学电子与光学工程系, 北京 101416; 2. 航天工程大学航天信息学院, 北京 1014163;  
3. 航天工程大学航天指挥学院, 北京 101416)

**摘要:** 为提高雷达目标识别 (radar target recognition, RTR) 系统的性能, 将机器学习应用于目标识别领域。总结归纳深度学习、神经网络、统计学习、集成学习 4 类主流 RTR 方法的优越性与缺陷, 分析优化措施, 提出 RTR 作为复合型的过程, 可以将机器学习各方法在目标识别中的优越性进行融合。结果表明: 将机器学习中的各类方法进行有机结合, 取长补短, 是未来基于机器学习 RTR 方法的发展趋势。

**关键词:** RTR; 深度学习; 神经网络; 统计学习; 集成学习

中图分类号: TN95 文献标志码: A

## A Survey of Radar Target Recognition Based on Machine Learning

He Yonghua<sup>1</sup>, Guo Qianyong<sup>2</sup>, Wu Peng<sup>2</sup>, Sang Xin<sup>3</sup>

(1. Department of Electronic and Optical Engineering, Space Engineering University, Beijing 101416, China;  
2. School of Space Command, Space Engineering University, Beijing 101416, China;  
3. School of Space information, Space Engineering University, Beijing 101416, China)

**Abstract:** In order to improve the performance of radar target recognition (RTR) system, machine learning is applied to the field of target recognition. This paper summarizes the advantages and disadvantages of four mainstream methods including deep learning, neural network, statistical learning and ensemble learning, analyzes the optimization measures, and proposes that, as a compound process, can integrate the advantages of machine learning methods in target recognition. The results show that the organic combination of various methods in machine learning is the development trend of based on machine learning in the future.

**Keywords:** RTR; deep learning; neural network; statistical learning; ensemble learning

## 0 引言

随着现代高科技战争中信息权的争夺愈发激烈, 雷达目标识别技术的应用得到了各国空前的关注和研究发展, 在导弹防御, 空域目标预警, 敌我识别, 威胁评估等军事领域发挥着至关重要的作用, 是目前取得信息优势的一种有效技术手段。

雷达目标识别 (RTR) 是指从雷达目标回波数据中提取目标的特征, 选择有关信息标志和较稳定各种特征对目标进行跟踪探测, 分类识别等。不仅能探测分析出目标所在位置、速度和高度等基本信息, 而且更重要的应用价值在于能细化判断出目标的类别、属性、结构、真假、所携带负载等信息, 以达到精准化识别目标的目的。

传统雷达目标识别通常是接收雷达传感器固定信息进行数字信号处理提取出待识别目标的特征, 利用已有的特征模板对提取的特征进行分类, 对照隶属度对目标进行识别。在日益复杂多变的识别环境下, 传统的识别方法因其泛化能力较弱、识别过

程对人的经验和知识的强烈依赖、对识别环境自适应能力较弱、识别效率低等缺陷, 已不能满足当下的目标识别要求。随着机器学习的不断发展, 机器学习因为其高智能化的特点, 开始被广泛应用于目标识别领域, 其中深度学习、神经网络、统计学习和集成学习为机器学习应用于目标识别领域的 4 个重要部分。笔者主要分析基于深度学习、神经网络、统计学习、集成学习的目标识别方法, 讨论了各方法的优缺点, 并且针对各方法的缺陷提出部分解决办法, 最后提出了将机器学习中各方法融合式地进行目标识别的研究趋势。

## 1 基于深度学习的目标识别方法

深度学习作为一种深层的神经网络, 在视音频处理、自然语义处理等方面应用已较为广泛, 取得了很好的效果。实际上, 深度学习对雷达目标的识别是通过构建很多隐层的机器学习模型和大量训练数据来实现对目标的自动特征提取。其学习对目标识别更有用的特征, 通常为隐层的抽象特征, 从而

最终提升分类或预测的准确性。通过计算机自动的逐层特征变换可以学习到输入数据的内在特征,使得分类识别更加容易,同时,模型结构的深度化也使得对复杂函数的特征表示能力更强。目前,应用于雷达目标识别的深度学习主要有:卷积神经网络(convolutional neural network, CNN)、深度置信网络(deep belief network, DBN)、稀疏自编码器(sparse autoencoder, SAE)。当前,CNN作为深度学习的重要组成,因为其局部连接及权值共享的特性,使得网络权值数量大为减少,模型复杂度大为降低,已成为图像处理领域效果最好的方法之一。文章深度学习部分主要分析基于上述3类深度学习的目标识别方法。

文献[1]针对窄带雷达群目标识别的显影特征较难提取,数据样本基数少以及识别实时性要求高的问题,提出了一种基于深度迁移学习的窄带雷达群目标识别方法。在深度学习技术特征提取的独特优势之上,发展了迁移学习来解决群目标显影数据少,模型训练耗时导致的实时性问题。最后,通过实验对比零基础深度学习和深度迁移学习2种方法,明显在准确率和耗时2方面上,深度迁移学习的学习效果更好。文献[2]方法以窄带雷达回波显影数据为基础,就窄带防控预警雷达对空中目标识别难的问题,提出了一种基于CNN的窄带雷达空中识别方法。该方法利用CNN强大的自动特征提取功能,使其不需要提前对数据特征人工处理,训练时就自动提取最有效目标特征,降低了对图像数据预处理的要求,使识别效率更高。最后从对比实验得出结论:如果采集雷达原始数据中的图像,采取数据增强手段生成数据集,能够使模型过拟合问题得到缓解,泛化能力得到提高。文献[3]方法利用一种基于双树复小波变换的非局部均值图像降斑算法,并结合目标方位角估计对原始数据进行鲁棒的预处理,有效提高了SAR图像的质量,并且保持了部分图像的细节信息,减少了因为旋转对SAR目标特征的影响。再利用深度置信网络有效地提取到了目标“重要”抽象特征。仿真实验结果表明,该方法的识别率较高且对噪声和旋转的鲁棒性较强,同时也暴露出了深度置信网络导致参数训练时间较长的问题。文献[4]针对现有空间微动目标识别方法耗时较长、要求目标观测时间大于一个微动周期、提取特征对单一回波的高度依赖性导致的低泛化性和低识别精度等问题,提出了一种基于稀疏自编码器的空间微动目标融合识别方法。其中利用CNN和

SAE逐步学习融合性有利于目标识别的隐层特征,充分挖掘利用了微动目标宽、窄带雷达回波中蕴含的丰富信息,使其具有较强的泛化能力。仿真实验结果证明:该方法与依赖单一回波的识别方法相比,识别正确率更高并且表现出了噪声稳健性。

上文中引用了基于3类深度学习网络的识别方法,结合目前发展趋势分析可知,深度学习应用于雷达目标识别的优越性主要体现在:1)自动特征提取,减少了技术人员对专业知识的依赖程度;2)提取目标重要的隐层特征,区别于常规识别方法中的物理特征,隐层的抽象特征更能代表目标特性且特征的泛化能力得到提升;3)模型结构的深度化使得对复杂函数的特征表示能力更强。

同时,基于深度学习的识别方法也有一定的缺陷:1)需要大量的训练数据作为支撑。目前,目标识别技术应用场景复杂,有很多重要识别目标可供提供学习的实际样本太少。2)隐层特征物理含义不明确,系统出现问题后难以定位。3)在深度学习数据训练过程中可能出现过拟合问题。针对上述3种缺陷。笔者总结了以下弥补方法:①针对训练数据的大需求问题。文献[1]中的方法可以利用深度迁移学习来解决深度学习过度依赖大量训练数据的问题,同时增强深度学习的实时性和适用性。也可利用数据增强技术,将小样本的训练数据经过数据增强后变为大量训练数据。在当前仿真技术日益发展的环境下,甚至可以采取基于目标特性的雷达目标数据增广,采用电磁散射建模仿真、实验室环境下模拟测量等手段实现数据样本扩充。获得的训练数据更为准确有效。也可以利用文献[5]提出的基于元学习算法,引入迁移学习思想的小样本学习方法,可以有效地进行小样本识别。②针对隐层物理含义不明确问题。文献[6]中提出将进动目标的雷达回波测试数据进行空间变换后得到的微动特征建立进动特征库,把进动特征库数据对深度学习网络进行训练,将得到的训练结果与目标进动参数建立关联关系,以此来对隐层参数进行物理解释。③针对数据训练过程中可能出现的过拟合问题。可以通过当前的正则化,数据增强等技术来进行弥补。

## 2 基于神经网络的目标识别方法

神经网络技术作为现代智能信息处理技术的主要方法之一,是由大量的神经元互联而构成的网络。因其具有对不确定性的自适应、自组织、自学习能力,使其在目标识别领域得到了广泛的应用。根据

互联方式的不同, 神经网络结构可以分为前馈神经网络、反馈神经网络、自组织神经网络。其中, 前馈网络中的 BP 神经网络(误差反向传播 BP)是人工神经网络中应用最广的一种神经网络。基于 BP 网络或其延伸形式的人工神经网络模型被广泛地使用于人工神经网络的实际应用中。主要分析基于 BP 神经网络的识别方法。BP 神经网络有对任意连续函数的强拟合能力, 构造简便、算法简单等特性, 从而被广泛应用于目标识别领域。

文献[7]针对雷达目标 1 维距离像的识别, 在 BP 神经网络的基础上, 结合了 PSO 优化算法(粒子群优化算法), 将粒子位置最优解作为 BP 神经网络的权值和阈值。基于 PSO-BP 的识别方法弥补了 BP 神经网络收敛速度慢、容易陷入局部极值的缺陷, 同时实验证明该方法识别效能有较大提升, 噪声鲁棒性增强。文献[8]在提取高分辨雷达目标回波信号特征的基础之上, 利用 BP 神经网络建立了一种基于 BP 神经网络的防空目标识别模型, 使得识别系统在样本足够多的情况下具有一定的记忆、容错和联想功能。对其进行训练过后, 其识别准确性和稳定性较高, 在很大程度上避免了因雷达或传感器误判导致的目标识别错误。文献[9]针对红外目标的识别分类, 提出了一种基于 BP 神经网络的红外目标识别方法。利用目标识别 BP 神经网络的记忆、联想、容错功能, 提高了目标识别的稳定度和可信度, 在一定程度上避免了因个别误判而造成的目标识别错误。文献[10]针对 BP 算法在目标识别中存在局部极值点, 收敛速度慢等缺点, 采用数字优化技术, 通过 LM 算法优化 BP 网络, 既提高了收敛速度又改善了识别率。文献[11]针对无源雷达目标识别问题, 提出了一种基于 BP 神经网络的目标识别模型。利用 BP 神经网络的特性在一定程度上弥补了无源雷达目标识别存在的识别率低和容错性不足等问题。

BP 神经网络在目标识别领域的优越性主要有: 1) 强映射能力。不需要关于输入与输出的精确数学关系, 对 BP 神经网络加以训练, 在学习一定数量的样本数据后, 就可实现任意输入与输出数据间的非线性映射。2) 识别系统具有记忆、容错和联想功能。其容错能力更是在很大程度上避免了由于目标识别过程中误判导致的错误。3) 强信息储存能力和巨量并行处理能力, 使目标识别过程变得更为简单, 提高了识别效率。

基于 BP 神经网络的识别方法也有一定的缺陷:

1) BP 神经网络收敛速度慢、存在多个局部极值点, 容易陷入局部极值的缺陷, 影响识别准确性; 2) 现实情况下较难获得强大有效的训练样本库。利用 BP 神经网络进行目标识别时, 需要一个强大有效的训练样本库。否则, 对目标的识别率将会降低。而由于当前在某些环境下, 很难得到重要待测目标的实际样本数据, 使得在实际中难以得到一个强大有效的训练样本库。

针对上述 2 种缺陷, 笔者总结了以下弥补方法: 1) 针对 BP 神经网络收敛速度慢, 存在多个局部极值点的问题。可以利用粒子群优化算法, 文献[7]利用粒子群优化算法较好的全局搜寻能力, 对 BP 神经网络的权值和阈值进行优化。缓解了收敛速度慢, 存在多个局部极值点的问题。可以利用数字优化技术——LM 算法, 文献[10]利用 LM 算法优化神经网络, 提高了收敛速度。2) 针对现实情况下较难获得强大有效的训练样本库。可以利用 D-S 证据理论。文献[12]提出利用 D-S 证据理论能将传感器多次提供的关于识别目标的信息不断融合起来, 达到对该目标的有效识别, 以此减小由于样本库较小所带来的不利影响, 提高系统的识别率。

### 3 基于统计学习的目标识别方法

统计学习是一种基于结构风险最小化准则而提出的机器学习理论, 本质是从样本数据中抽象出概率统计模型, 再利用模型对新的数据进行分析和预测<sup>[13]</sup>, 在解决小样本的学习问题方面具有优势。基于统计学习理论的机器学习算法运用于雷达目标识别方向上时, 采用较多的主流方法包括有 K 近邻法 (K-nearest neighbor, KNN)、支持向量机法 (support vector machines, SVM) 以及决策树 (decision tree, DT) 等。

#### 3.1 KNN 算法

KNN 是一种非常有效的惰性学习非参数分类算法。其学习过程简而言之就是将每个样本用与其最接近的 K 个邻近值来代表, 如果这 K 个最相邻样本中的大多数属于同类别, 则预测该样本也为此类别。文献[14]利用经过剪裁和去噪处理后的图像信息作为提取特征, 随后对 3 类不同目标运用 KNN 算法分别进行了仿真识别, 结果表明对于 3 类目标的识别准确率均达到 94% 以上, 取得了良好的识别效能。文献[15]提出一种基于时间—质心分布的改进 KNN 算法对目标个体进行分类识别的方法, 使用待分类样本与 K 个近邻样本质心的距离来代替待

分类样本与训练样本之间的距离进行分类, 有效增大了不同类样本间的距离, 提升了分类正确率。

### 3.2 决策树算法

决策树是一种有指导的机器学习算法, 其目的是建立分类或回归模型, 在学习训练样本的基础上, 建立分类规则对其他样本进行分类; 因其表现方式像是一棵倒立的树, 所以称之为决策树。文献[16]以已知的目标雷达参数集作为数据库, 提出了一种基于决策树算法的识别目标雷达型号的方法, 通过仿真得到对 6 类雷达型号的较高识别准确率, 验证了决策树算法运用与雷达目标识别的可行性。文献[17]提出了一种基于决策树和支持矢量描述(SVDD)的改进分类算法并用于空天时敏目标识别问题, 通过序贯脉冲积累和时域滑窗的方法提取统计特征, 将提取的高维特征用于改进分类识别算法中, 通过对 4 类飞机的仿真结果表明, 随着识别次数的增加, 4 类目标的平均累积识别率都稳定在 80% 左右, 有效解决了空天时敏目标识别敏感性的问题。

### 3.3 SVM 算法

SVM 分类算法是按照监督学习方式的一种二类分类模型, 其主要思想是构建几何间隔最大的分离超平面使得不同类别的样本被尽可能地分隔开, 然后通过核函数将新增的样本特征映射到高维特征空间, 依据落在空间平面的位置来预测其所属类别。文献[18]提出一种基于 SVM 的雷达目标识别方法, 提取识别对象飞机尾涡速尾度极差特征, 并融合温度、气压、风速、风向 4 种环境因素作为数据库, 构建所需的 SVM 求解模型, 最后以识别准确率(ACC)和 ROC 曲线下的面积(AUC)为评估标准, 结果表明, 该方法获取的 ACC 和 AUC 为 0.850 和 0.920, 相较于其他识别方法准确率有显著的提升。文献[19]针对传统的渐进直推式支持向量机学习算法存在的缺陷, 笔者提出了改进的快速渐进直推式支持向量机学习算法(fast progressive transductive support vector machine learning, FPTSVM), 利用区域标注法(region labeling rule)取代 PTSVM 算法的成对标注法, 增加无标签样本数量从而提高算法的速度。文献[20]提出一种结合 SVM 与 KNN 的非参数类间散布矩阵构造方法——SVM-KNN, 通过将此方法用于原始样本数据进行特征提取, 减小非类边界样本对类边界结构信息的扭曲, 从而达到提高雷达识别效率的目的。文献[21]基于 SVM 算法原理构建了一种融合决策树-支持向量机 2 种算法的分

类识别模型用于毫米波雷达的目标识别分类, 首先将 SVM 分类器排列成 2 层平衡二叉决策树模型结构, 选取 Poly 作为 SVM 分类器的核函数, 随后对 4 类目标类型进行分类识别, 结果表明局部分类器和总体分类识别系统的训练与测试准确率均在 88% 以上, 最终决策树-SVM 系统的分类识别准确率为 91.06%, 总体性能较好, 具有较强的学习能力及泛化能力。

### 3.4 统计学习算法优缺点

1) 基于统计学习的各方法在雷达目标识别中已取得诸多应用, 算法能力得到了研究人员的大力发掘, 大致可将优势概括如下。

① KNN 算法: 算法简单、易于理解; 包容型数据的特征变量筛选尤其有效; 处理低维空间数据时效果很好, 适用于类域交叉或重叠较多的样本。

② 决策树算法: 处理高维空间大数据样本效果好; 生成的规则集模型解释性强; 分类速度快、计算量小。

③ SVM 算法: 系统结构简单; 全局最优; 推广能力强。

2) 在实际应用中, 也表现出如下局限性:

① KNN 算法:

$k$  的取值对算法有很大的影响: 若选择较小的  $k$  值, 模型的近似误差会减小, 但估计误差会增大, 预测结果会对近邻的实例非常敏感, 同时也会放大噪声数据的干扰, 模型容易发生过拟合; 如果选择较大的  $k$  值, 模型的估计误差会减小, 但近似误差会增大, 包含非相似数据过多从而对预测产生影响, 过大的  $k$  值往往也会使模型变得过于简单。实际应用中, 通常使用交叉验证法来确定  $k$  最优的取值。

多标签问题应用受限: 针对于这一缺点的改进主要有多标签学习 KNN 算法, 例如文献[22]提出的一种改进的 MLKNN 算法, 利用带有标签概率的数据特征训练分类模型, 取得了良好的多标签分类学习效果。

② 决策树算法:

容易出现过拟合问题: 如果一个决策树模型的结构过于复杂, 那其分类规则将非常冗长, 导致模型解释性变差, 就容易产生过拟合。文献[23]在参考 GUIDE 和 Cline 等算法改进方向的基础上, 在保持准确率的同时, 提出了 4 种基于线性判别分析的双变量决策树算法, 有效缩减模型规模, 对模型进行了剪枝优化处理。

处理连续型变量时划分效率低: 经典决策树分类算法都存在无法直接处理连续型自变量的问题, 对连续型自变量的处理方式基本都是先将其离散化为分类型, 再用处理分类型自变量的手段处理连续型自变量, 这个过程通常导致决策树算法的处理效率低下。解决此类问题一般采用基于线性判别分析的方法。

③ SVM 算法在样本数据量过大时会导致训练效率偏低。SVM 分类算法运用于大规模训练样本时略显吃力, 原因是由于 SVM 算法是基于 2 次规划理论(QP)求解支持向量, 而解决 2 次规划问题将包含  $m$  阶矩阵的计算( $m$  为样本的个数), 而当  $m$  数目很大时, 将耗费大量的计算机内存和时间来存储和计算该矩阵<sup>[24]</sup>。针对此种问题的主流解决途径有 SVM 增量训练算法、排序支持改良向量机等方法。

## 4 基于集成学习的目标识别方法

集成学习是数据挖掘算法的一种, 其本质上是将多个基分类器通过有效融合集成为一个强分类器来完成学习任务, 在提高分类精度的同时也能获得比单一基学习器更加优异的泛化性能和鲁棒性。根据基分类器的生成顺序可以将集成学习基本分为 3 大类: 串行组合、并行组合和混合拓扑组合。经典的集成学习方法 Boosting 以及其后续衍生的 AdaBoosting、梯度增强决策树 (gradient boosting decision tree, GDBT) 等方法都属于串行组合<sup>[25]</sup>; Bagging 算法以及在此基础上改进的随机森林算法属于并行组合结构; 混合拓扑组合有 2 阶段集成学习 TPEL 等方法<sup>[26]</sup>。

### 4.1 AdaBoosting

文献[27]针对传统的 AdaBoost 算法在高维数据中精度下降, 受噪声影响大的问题, 提出了一种基于 SVM 作为弱分类器的改进 AdaBoost 算法, 提升了在非线性和高维应用环境下的分类器性能。文献[28]提出了一种基于原始 AdaBoost 算法, 结合纠错输出码进行多类别推广后的 AdaBoost. ECOC 算法: 首先, 借助已经基于自适应哈达玛矩阵编码方法的纠错识别码矩阵为每个分类器分配长度为  $n$  的码字; 随后, 采用 AdaBoost 方法训练出新的识别码与原有识别码进行比较, 利用纠错识别码的纠错特性提高了分类器的泛化能力。通过与其他几种处理方法对比的仿真结果表明, 该方法在提高处理 SAR 合成孔径雷达图像目标识别准确率中有着显著效用。

文献[29]针对雷达目标高分辨 1 维距离像 (HRRP) 具有维数高、非线性特征雷达目标识别困难的问题, 提出了一种结合线性判别分析 (LDA)、核 Fisher 判别分析 (KFD) 与 AdaBoost 算法的雷达目标识别方法: 先利用 LDA 与 KFD 对样本进行降维特征提取, 后基于 AdaBoost 算法进行分类识别。由仿真结果表明, 此种基于 AdaBoost 的方法能取得优于其他目标识别方法 60% 左右的识别分类效能。

### 4.2 Bagging

随机森林是一种 Bagging 的扩展变体方法, 不同的是随机森林在原方法的基础上采用决策树作为其基学习器来构建模型。随机森林的基本思想是利用 Bootstrap 抽样方法子训练集, 对每个子训练级建立决策树模型, 所有决策树进行投票来确定样本类型。文献[30]针对条纹管激光雷达系统对于雷达目标识别数据处理要求高时效性、高准确性的问题, 提出了基于随机森林的分类模型算法, 构建由 130 个基决策树组成、最大基决策树深度为 8 的随机森林模型, 仿真结果最优分类准确率达到了 89.3%, 表明此种随机森林算法在处理海量数据方面时具有显著优势。文献[31]针对传统的 HRRP 识别方法存在模型——数据失配以及计算复杂度大等问题, 提出了一种基于随机森林的 HRRP 识别方法, 选取散射点模型来描述目标特性, 从样本的特征中选取 11 个作为内部节点的候选分裂特征, 再由 100 个决策树组成随机森林, 开展对 3 类目标的仿真识别, 结果表明, 基于随机森林的算法在避免传统识别方法所导致的模型——数据失配等问题的同时, 也取得了平均识别率达到 97.2% 的最优识别性能。文献[32]针对临近空间高超声速再入滑翔飞行器 (hypersonic reentry-glide vehicle, HRGV) 滑翔段飞行状态识别问题, 提出了一种基于随机森林的识别方法: 首先, 将目标飞行状态分为 6 类并基于运动方程分别进行仿真得到初始样本数据, 引入信息增益和信息增益率筛选所需的特征属性; 最后, 运用随机森林模型完成分类器识别和跟踪轨迹识别任务。仿真结果表示, 分类器识别任务下, 准确率基本达到 100%; 跟踪轨迹识别任务下, 2 种轨迹识别准确率均达到优异性能, 分别为 100% 和 81.7%。

### 4.3 集成学习优缺点

1) 集成学习具有良好的学习效果, 提供了一种算法框架把普通分类器提升为强分类器, 即使在数据特征不多的条件下仍然具有较好的分类效果, 取

得较好的分类精度。AdaBoost 算法不需要系统进行初始的特征筛选,也不用考虑出现过度拟合等问题。在模式识别、函数逼近、数据挖掘和非线性系统控制等领域中均具有很好的应用前景。随机森林结构简便,计算所需资源小,易于训练,不需要对样本的统计分布进行假设,也不用通过多次实验确定核参数,在雷达目标识别中具有良好的应用前景。

2) 基于集成学习的识别方法在运用中也暴露出来了一些缺陷。

### ① AdaBoost 算法:

基分类器的选择对识别结果影响较大。AdaBoost 算法最核心的思想就是选取和训练基分类器问题,传统分类器并不适用于更复杂的识别需求,在实际应用中,不同的应用场景应该根据具体需求选取改进型基分类器,针对不同类型的雷达识别目标需要选择合理的基分类器,例如针对高维数据中应用传统 AdaBoost 分类器出现的精度明显下降,受噪声影响极大,在复杂目标数据流环境中错误率激增等问题,文献[27]提出选用 SVM 分类器作为弱分类器对传统 AdaBoost 算法进行改进,可以有效提升在非线性和高维应用环境下的分类器性能,从而满足高维数据中识别精度的要求。

基本理论只考虑了最简单的 2 类分类情况。将 AdaBoost 算法直接应用于多分类问题将由于弱分类器条件过强而分类失败,无法推广到多分类问题的应用上。解决途径是引入二分类拆解的思想-拆解法是在原有二分类的弱分类器条件下将多分类问题拆解为多个二分类问题,从而避免了构造复杂多分类条件下的弱分类器。例如文献[27]提出的结合纠错识别码方法,可以将多类问题拆解为多个 2 类问题,从而成功地将 AdaBoost 推广到多类别分类的应用。

### ② 随机森林算法:

无标准的森林规模规定。随机森林一大特点就是可以支持并行计算,算法相对能取得更快的速度,但若森林规模过大则会出现模型冗余的问题,计算耗费过多从而降低分类效率。文献[33]提出了一种基于优化 4 种 Margin 的度量方式达到最优化递归消除的森林修剪方式,有效达到适当缩减模型规模,消除树间隔冗余的目的。

针对连续性变量要进行离散化处理。传统的随机森林方法处理样本数据中的连续变量是采用将其区分为不同区间的方法,即离散化。但此举会导致算法在分析计算节点分裂标准时时间成本大大增

加,拖慢算法执行速度。目前连续变量离散化最主要的方法是基于统计学思想的 CHI2 相关算法。

## 5 结束语

为提高雷达目标识别系统的性能,应将机器学习中的各类方法进行有机融合,取长补短,例如文献[34]中在传统的卷积神经网络的基础上将 Softmax 分类器替换成随机森林,得到 CNN 与 RF 相结合的 CNN-RF 算法,在实测结果中取得了更高的目标识别准确率。

## 参考文献:

- [1] 梁复台,李宏权,张晨浩. 基于深度迁移学习的窄带雷达群目标识别方法[J]. 兵器装备工程学报, 2020, 41(4): 143-147.
- [2] 梁复台,李宏权,刘安波,等. 基于 CNN 的窄带雷达空中目标识别方法[J]. 火力与指挥控制, 2020, 45(6): 85-90.
- [3] 何松华,张润民,欧建平,等. 基于卷积神经网络的高分辨率雷达目标识别[J]. 湖南大学学报(自然科学版), 2019, 46(8): 141-148.
- [4] 田旭东,白雪茹,周峰. 基于稀疏自编码器的空间微动目标融合识别方法[J]. 电子与信息学报, 2023: 1-9.
- [5] 孙晶明,虞盛康,孙俊. 基于元学习的雷达小样本目标识别方法及改进[J]. 系统工程与电子技术, 2022, 44(6): 1839-1845.
- [6] 李波,任红梅,肖志河. 人工智能在雷达应用中的限制和发展前景[J]. 军事文摘, 2019(3): 42-44.
- [7] 王泓霖,李伟,许强,等. 基于 PSO-BP 神经网络的 HRRP 目标识别[J]. 火力与指挥控制, 2019, 44(12): 39-44.
- [8] 刘千,王堃. 基于 BP 神经网络的防空目标识别方法[J]. 工业仪表与自动化装置, 2015(2): 94-98.
- [9] 范浩锋,刘俊. 基于 BP 神经网络的红外目标识别技术[J]. 计算机与数字工程, 2013, 41(4): 559-560, 653.
- [10] 侯亚丽,李铁. 基于 LM 优化算法的 BP 神经网络目标识别方法[J]. 探测与控制学报, 2008, 30(1): 53-57.
- [11] 蔺美青,蔡铁. 无源雷达目标识别的神经网络模型构建[J]. 雷达科学与技术, 2019, 17(5): 557-563.
- [12] 人工神经网络在目标识别和分类中的应用[J]. 海军航空工程学院学报, 2005, 20(4): 401-404.
- [13] 孟磊,曲卫,蔡凯,等. 基于机器学习的雷达辐射源识别方法综述[J]. 兵器装备工程学报, 2020, 41(10): 16-21.
- [14] 郝岩,白艳萍,张校非. 基于 KNN 的合成孔径雷达目标识别[J]. 火力与指挥控制, 2018, 43(9): 111-113, 118.

(下转第 51 页)