

基于微多普勒效应和 AR 模型的 车辆目标分类方法

李开明¹, 张 群^{1,2,3}, 罗 迎^{1,2,3}, 丁帅帅¹, 郭 英¹

(1. 空军工程大学信息与导航学院, 陕西西安 710077; 2. 复旦大学电磁波信息科学教育部重点实验室, 上海 200433;
3. 信息感知技术协同创新中心, 陕西西安 710077)

摘 要: 轮式车辆和履带式车辆的分类是地面目标识别的难点之一. 车轮旋转和履带的运动是典型的微动, 其产生的微多普勒特征可作为两类车辆目标分类的重要依据. 首先, 针对短驻留条件下两类车辆目标的雷达回波, 分析了两类目标不同微动导致的微多普勒特征差异; 其次, 基于目标回波短时平稳相关的性质, 建立了目标回波的 AR 模型, 采用前后向预测方法得到相应的 AR 模型系数, 提出基于 AR 模型系数的车辆目标分类方法, 并给出 AR 模型阶数的判定方法, 对比了前后向预测系数特征与前向预测系数特征的可分性. 最后, 结合两类目标的实测数据, 在回波预处理的基础上, 通过提取实际回波数据的 AR 模型系数实现了车辆目标的分类, 验证了方法的有效性和稳健性.

关键词: 微多普勒; AR 模型; 前后向预测; 车辆目标; 分类

中图分类号: TN957 **文献标识码:** A **文章编号:** 0372-2112 (2018)04-0805-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2018.04.006

A Classification Method of Vehicle Targets Based on Micro-Doppler Effect and Auto Regression Model

LI Kai-ming¹, ZHANG Qun^{1,2,3}, LUO Ying^{1,2,3}, DING Shuai-shuai¹, GUO Ying¹

(1. School of Information and Navigation, Air Force Engineering University, Xi'an, Shaanxi 710077, China;

2. Key Laboratory for Information Science of Electromagnetic Waves (Ministry of Education), Fudan University, Shanghai 200433, China;

3. Collaborative Innovation Center of Information Sensing and Understanding, Xi'an, Shaanxi 710077, China)

Abstract: The classification of the wheeled vehicles and tracked vehicles is one of the difficulties of vehicles recognition. Rotation of the wheels and running of the track are the typical forms of micro-motion, the micro-Doppler signatures of the micro-motion can be the crucial proof for classification of the two kinds of vehicles. Firstly, the micro-Doppler difference of different micro-motion of the two vehicles are analyzed based on the echoes under radar with short dwell time; Secondly, based on the short-time stability and correlation of the echoes, the Auto Regression (AR) model of echoes is established, the forward and backward prediction method is applied in the extraction of AR model coefficients, which are used in the classification of the two kinds of vehicles, and the selection of the order of AR model is operated, the separation abilities between forward and backward prediction coefficients and forward prediction coefficients are compared; At last, after the pre-processing of the measured data, the classification of the two vehicles is accomplished with high accuracy based on the extraction of AR model coefficients. The effectiveness and robustness of the method are proved by the simulation results.

Key words: micro-Doppler; auto regression model; forward and backward prediction; vehicle target; classification

1 引言

轮式车辆和履带式车辆是重要的地面军事目标, 对两类目标的分类研究对于战场态势感知、威胁评估、

精确打击等具有积极的军事意义^[1,2]. 上世纪 70 年代, 美国就开展了车辆目标识别研究, 主要通过采集车辆行进时产生的地震动信号、声信号和磁信号等进行识别^[3-7]. 90 年代, 美国国防部高级研究计划局又提出

MSTAR 计划,出动各类轮式和履带式车辆进行信号采集和实验^[3].文献[8~12]分别提取了包含车辆目标的红外图像^[8]、SAR 图像^[9]、极化图像^[10]、激光雷达图像^[11]、光学图像^[12]的特征,完成车辆目标识别.文献[13]针对不同车辆目标高分辨距离像的特征差异,实现了坦克、卡车、轮式装甲车的分类.文献[14,15]基于回波多普勒谱的特征差异完成了轮式与履带式车辆的分类.国内,南京理工大学的聂伟荣教授和哈尔滨工业大学的冀振元教授较早开展了车辆目标的分类研究^[4,15].

微多普勒特征是雷达目标独一无二的特征^[16,17],可为目标的分类识别提供参考和依据^[1,2,18~20].文献[19]基于不同种类和型号坦克炮塔激励的微多普勒特征差异,提出对坦克参数估计和身份识别的方法.文献[2]采用多级小波分解获得不同车辆的多普勒谱分量,并提取能量比和幅度比作为特征完成轮式和履带式车辆的分类.当前,基于微多普勒特征的目标分类方法包括两类:一是从参数提取的角度.首先提取目标微多普勒特征参数,然后进行特征重构,最后完成特征选择和分类.这类方法往往运算相对复杂,且参数提取精度受雷达带宽、目标微动幅度、微动频率、环境噪声等多种因素的影响.二是从信号分解的角度.将多普勒分量与微多普勒分量分离,再进行特征提取和分类.这类方法破坏了目标回波信息的完整性,导致提取的特征信息受到影响.实际中,雷达除了要具备目标识别功能外,还要求能同时完成大范围目标搜索、多目标跟踪定位等任务,这些功能均占用雷达的时间资源,导致雷达很难对单个目标进行长时间观测.

雷达目标回波是典型的非平稳信号,但短相关处理间隔(coherent processing interval, CPI)内目标的运动更接近平稳,且目标散射特性相对稳定,可以认为在较短时间内目标回波满足短时平稳相关性,即可用短时平稳信号来近似.此时可以用时间序列的自回归(auto-regression, AR)模型来逼近目标回波,同时基于线性预测误差最小准则可得到唯一一组 AR 模型系数来表征目标回波非平稳序列.目前,AR 模型被广泛用于系统辨识与目标分类^[20~22].文献[20]对人体不同微动的回波信号进行前向预测,提取 AR 模型系数作为特征完成了人体不同微动姿态的分类.本文针对短驻留条件下的车辆目标回波,分析了不同车辆目标的微多普勒特征差异,基于目标回波的短时平稳相关性,建立了相应的 AR 模型.在此基础上,基于实测数据给出复信号条件下数据预处理及 AR 模型阶数判定方法,对比了前向预测系数特征与前后向预测系数特征的可分性,最后以不同车辆目标回波的 AR 模型系数为特征,实现了轮式和履带式车辆的分类.

2 车辆目标回波分析

2.1 轮式车辆回波分析

车轮旋转是轮式车辆的主要微动形式,而履带式车辆结构相对复杂,其微动主要包括负重轮的旋转和履带的运动.为简化分析,假设目标处于雷达光学区,可以用散射点模型来描述目标回波.不考虑目标的三维旋转,在二维平面内对车辆目标微动部件进行回波建模.图1为轮式车辆车轮旋转示意图,雷达位于坐标原点 O ,记初始时刻雷达到车轮旋转中心 O' 的距离为 R_0 ,车轮半径为 r ,轮毂半径为 r_1 ,车辆以速度 v_1 远离雷达运动,轮毂边缘散射点 P 以角速度 Ω 、初始相位 θ_0 沿 X 轴正方向前进.




图1 轮式车辆车轮旋转示意图

假设雷达发射单频信号的表达式为 $s_c(t) = \exp(j2\pi f_c t)$,其中 f_c 为载频.对于轮式车辆,非旋转点包括车身体点和轮毂中心.对轮毂中心 O' , t 时刻其到雷达的距离为 $R_1 = R_0 + v_1 t$,轮毂旋转散射点 P 到雷达的距离为 $R_2 = R_{op} \approx R_0 + v_1 t + r_1 \cos(\Omega t + \theta_0)$,此时雷达回波可表示为

$$s_R(t) = \sigma_1 \exp(j2\pi f_c (t - \tau_1)) + \sigma_2 \exp(j2\pi f_c (t - \tau_2)) \quad (1)$$

其中, $\tau_1 = 2R_1/c$, $\tau_2 = 2R_2/c$, c 为光速, σ_1 、 σ_2 分别为旋转中心 O' 和旋转点 P 的散射系数.

对回波信号 $s(t)$ 进行去载频处理后,对其相位关于时间 t 求导,可得:

$$f_{D1} = -kv_1 \quad (2)$$

$$f_{D2} = -k(v_1 - \Omega r_1 \sin(\Omega t + \theta_0)) \quad (3)$$

其中, $k = 4\pi f_c/c$.可以看出,轮式车辆回波在频域表现为非旋转点单频形式的多普勒分量和旋转点正弦调频形式微多普勒分量的叠加.

2.2 履带式车辆回波分析

图2为履带式车辆运动示意图,雷达位于坐标原点 O ,设车辆有 n 个负重轮,以速度 v_2 远离雷达运动,记上履带长度为 L_1 ,下履带长度为 L_2 ,侧履带与地面的夹角为 φ ,由于履带转弯部分与负重轮旋转相似且长度很短,这里重点考虑履带四条边的微动.在履带四条边上各取一个散射点 A 、 B 、 C 、 D ,记上排中间的负重轮轴心为 O' ,其在 X 轴的投影记为 Q ,记 $R_{OQ} = R_r$,负重轮半径为 r_0 ,其边缘旋转点 P_0 以角速度 Ω_0 、初始相位 θ_{00} 绕轴心 O' 旋转.

履带式车辆的非旋转点包括车身体散射点和负




图2 履带式车辆运动示意图

重轮轴心. 以负重轮轴心 O' 为例, 记初始时刻其到雷达的距离为 $R_{O'O'} \approx R_T$, 则 t 时刻其到雷达的距离为 $R_{O'O'}(t) \approx R_T + v_2 t$, 此时履带上所有散射点的瞬时线速度大小均为 v_2 , 只是方向不同.

则对上履带的 A 点, t 时刻其到雷达的距离为 $R_A(t) \approx R_{O'O'}(t) + v_2 t = R_T + 2v_2 t$; 对于下履带的 C 点, 其相对于地面保持静止, t 时刻其到雷达的距离为 $R_C(t) \approx R_{O'O'}(t) - v_2 t = R_T$; 进一步, 对于右侧履带的散射点 B , t 时刻其到雷达的距离为 $R_B(t) \approx R_T + v_2 t + L_1/2 + r_0 - v_2 \cos\varphi \cdot t$; 对于左侧履带的散射点 D , t 时刻其到雷达的距离为 $R_D(t) \approx R_T + v_2 t - L_2/2 - r_0 - v_2 \cos\varphi \cdot t$; 对于负重轮边缘的旋转点, 以 P_0 为例, 则 t 时刻其到雷达的距离为 $R_{P_0} \approx R_T + v_2 t + r_0 \cos(\Omega_0 t + \theta_{m0})$.

同样, 对履带各散射点、负重轮边缘旋转点的回波分别去载频, 然后对其相位关于时间 t 求导, 可得履带式车辆多普勒频率成分包括: $f_{D1} = -kv_2$, $f_{D2} = -2kv_2$, $f_{D3} = -kv_2(1 - \cos\varphi)$, $f_{D4} = -k(v_2 - r_0\Omega_0 \sin(\Omega_0 t + \theta_{m0}))$, 其中, $k = 4\pi f_c/c$. 可见, 上履带微多普勒分量为主体多普勒的两倍, 而侧履带微多普勒小于主体多普勒, 同样负重轮旋转点的微多普勒分量分散在主体多普勒的两边.

3 基于 AR 模型的车辆目标分类

图 3 和图 4 分别为轮式车辆和履带式车辆实测数据的单帧回波(约 9ms)及其频谱, 从图 4(b) 可以看出, 履带式车辆上履带的微多普勒分量较为明显, 而侧履带微多普勒分量并不明显, 这是因为实际中侧履带通常较短且受遮挡的影响; 同时轮式车辆车轮和履带式车辆负重轮的微多普勒分量都较为微弱.






图3 两类车辆目标实测数据单帧回波



(a) 轮式车辆回波频谱



(b) 履带式车辆回波频谱

图4 两类车辆目标实测数据单帧回波频谱

3.1 车辆回波 AR 预测模型及其系数求解

通过上面的仿真分析可以发现, 上履带微多普勒特征是轮式和履带式车辆的重要特征差异. 传统的微多普勒参数估计往往需要复杂的信号分解重构算法, 有的还需要借助时频分析工具, 同时需要较长的时间积累, 至少需要整数倍的微动周期, 对雷达带宽、载频也提出较高要求. 对于车辆目标单帧回波而言, 通常为毫秒量级, 很难观察到整周期的微动. 线性预测编码是一种有效分析短时信号的工具. 从图 4 可以看出, 在较短的相干处理间隔(CPI)内, 目标回波的相邻离散采样具有较强的相关性, 这种相关性可通过 AR 模型来描述^[21,22], 即可以近似认为当前采样点幅值是其附近若干个采样点幅值的线性组合.

将两类车辆目标的单帧离散回波(即一个 CPI 内的回波数据)分别记作 $S(M)$ 和 $S_1(N)$, M 和 N 分别为两类目标单帧回波一个 CPI 内的离散采样点数. 常用的 AR 模型系数求解方法有自相关法和 Burg 算法, 与自相关法相比, Burg 算法避免了由有限个数据估计自相关函数及矩阵求逆, 在短数据下的谱估计更加准确、稳健, 频率分辨率更高^[21]. 同时, Burg 算法基于前向和后向预测误差之和最小, 可利用两倍于前向预测方法的数据最优地估计 AR 模型系数^[21].

以轮式车辆为例, 对于满足 AR 模型的单帧离散回波信号 $S(M)$, 其前向预测表达式可记为 $S^f(m) =$

$-\sum_{i=1}^p a_i S(m-i)$, $S^f(m)$ 表示前向预测数据, m 为离散采样点数, p 表示 AR 模型阶数, a_i 表示 AR 模型系数, 后向预测表达式可记为 $S^b(m-p) = -\sum_{i=1}^p a_i^H S(m-p+i)$, $S^b(m-p)$ 表示后向预测数据, $[\cdot]^H$ 表示共轭转置. a_i 的求解可通过前后向预测误差最小来实现. 则前后向预测误差可表示为:

$$e_p^f(m) = S(m) - S^f(m) \quad (4)$$

$$e_p^b(m) = S(m) - S^b(m) \quad (5)$$

此时, 前后向预测误差构成格型滤波器, 则前后预测误差和后向预测误差可以分别表示为 $e_p^f(m) = e_{p-1}^f(m) + k_p e_{p-1}^b(m-1)$ 和 $e_p^b(m) = e_{p-1}^b(m-1) + k_p^* e_{p-1}^f(m)$, k_p 为反射系数. 则前后向预测误差平均功率可表示为^[22]:

$$\rho_p = \frac{1}{2(M-p)} \sum_{m=p}^{M-1} [|e_p^f(m)|^2 + |e_p^b(m)|^2] \quad (6)$$

求解 ρ_p 最小时的反射系数 k_p , 得^[22]:

$$k_p = \frac{-2 \sum_{m=p}^{M-1} e_{p-1}^f(m) e_{p-1}^{b*}(m-1)}{\sum_{m=p}^{M-1} [|e_{p-1}^f(m)|^2 + |e_{p-1}^b(m-1)|^2]} \quad (7)$$

依据 Levinson 递推公式可求出 AR 模型参数为:

$$\begin{cases} a_{p,i} = a_{p-1,i} + a_{p,p} a_{p-1,p-i}^*, 1 \leq i \leq p \\ a_{p,p} = k_p \\ \rho_p = (1 - k_p) \rho_{p-1} \end{cases} \quad (8)$$

3.2 基于实测数据的 AR 模型系数求解与目标分类处理

实际车辆回波为短驻留条件下的雷达回波数据, 相干处理间隔为毫秒级, 此时目标回波的 AR 模型假设是成立的. 同时, 实际车辆目标回波受强地杂波、车身速度和姿态变化以及各种随机干扰的影响, 从而影响目标特征提取和分类, 必须通过回波预处理对其进行有效抑制.

(1) 地杂波抑制 实际车辆目标的回波往往包含大量随机地物杂波, 分布在零频附近. 当车身速度较小时, 杂波谱与车辆微多普勒谱混叠在一起, 对车辆目标的特征提取与分类带来影响.

图 5 为地面车辆目标远离雷达姿态下多帧实测数据的多普勒谱, 可见地杂波集中在 0 频附近, 且强度大于微多普勒分量; 同时可以发现, 由于轮式车辆的车轮外缘为橡胶材质, 散射较弱, 轮毂半径相对较小, 因此微多普勒分量相对较弱, 而履带式车辆负重轮为金属材料, 散射较强且半径较大, 因此微多普勒分量较强, 上履带的微多普勒分量更加明显, 与理论分析一致.

(2) 车身多普勒频率归一化 实际中, 车辆目标相

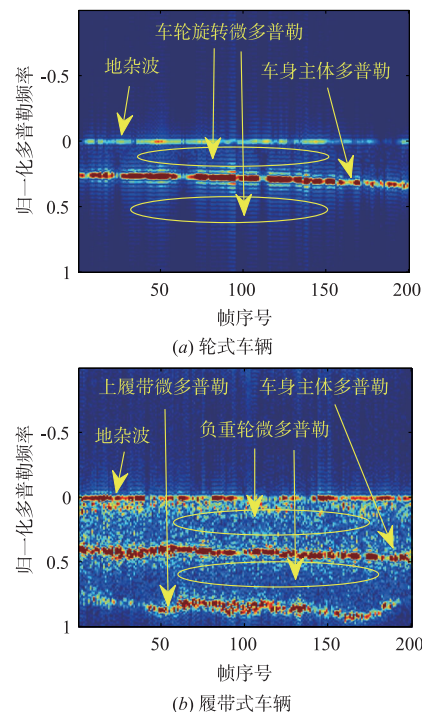


图5 车辆目标多帧回波多普勒谱

对于雷达的运动并非理想的匀速直线运动. 从图 5 可见, 不同帧数据之间, 轮式和履带式车辆的车身主体多普勒是缓慢时变的. 而车身速度变化时, 同一目标的两帧数据对应的多普勒谱也会体现出差异性. 对于目标分类问题, 我们总是希望保留同一目标数据之间的相似性, 因此需要对车身主体多普勒频率进行归一化, 消除车身速度变化对分类的影响.

(3) 样本筛选 实际目标回波受多种因素的影响, 目标回波质量并不稳定. 从图 5 可以看出, 轮式车辆部分帧数据中车身主体多普勒分量较弱, 履带式车辆的部分帧数据的车身主体多普勒分量和上履带微多普勒分量也比较弱, 都存在一些不连续的断点. 因此, 为提高分类的效率和精度, 需要对回波数据进行筛选, 对质量较差的帧数据进行剔除, 保证样本的高质量.

3.3 AR 模型阶数判定与目标分类

常用的确定 AR 模型阶数的方法有最终预测误差 (FPE) 准则和阿凯克信息论 (AIC) 准则^[22]. 对于短记录数据, AIC 准则估计性能更好, 但这两种模型阶数估计法实际中仍存在过高估计阶数的可能^[22]. 需要注意的是, 基于实测数据的车辆目标分类需要随机抽取多帧预处理后的回波数据, 以尽量涵盖车辆目标各种姿态下的回波, 保证训练样本的充分性和多样性, 并将相邻帧数据之间的相关性降到最小, 使分类更加真实可靠. 其次, 实际中的雷达回波数据为复矩阵, 得到的 AR 模型系数同样是复系数, 此时 k_p 应取为共轭转置形式.

基于以上分析, 分别记轮式和履带式车辆的回波

矩阵为 S 和 S_1 , 大小均为 $P \times Q$, 其中 P 表示离散采样点数, Q 表示回波帧数, 其对应的傅里叶变换矩阵(回波频谱)分别记为 F_S 和 F_{S_1} , 脚标 S 和 S_1 分别代表轮式和履带式车辆. 则基于 AR 模型的车辆目标微多普勒表征及分类方法的具体实现步骤如下:

Step 1: 对回波频谱矩阵 F_S 和 F_{S_1} 分别乘以滤波器 F_1 , 滤除地杂波, 得到 \tilde{F}_S 和 \tilde{F}_{S_1} ;

Step 2: 记录 \tilde{F}_S 和 \tilde{F}_{S_1} 的每帧回波的多普勒频率, 分别记为 f_s 和 f_{s_1} , f_s 和 f_{s_1} 均为 $1 \times Q$ 的行向量. 在 \tilde{F}_S 和 \tilde{F}_{S_1} 内分别搜索各自回波的最大多普勒频率, 分别记为 f_{\max} 和 $f_{1\max}$, 分别求出每帧回波多普勒频率与最大多普勒频率的比值, 记为向量 ε 和 ε_1 , 其中 $\varepsilon = f_s / f_{\max}$, $\varepsilon_1 = f_{s_1} / f_{1\max}$. 对 \tilde{F}_S 和 \tilde{F}_{S_1} 的每一帧分别以 ε 和 ε_1 进行重采样完成车身多普勒频率的归一化, 得到的新矩阵记为 \bar{F}_S 和 \bar{F}_{S_1} ;

Step 3: 对 \bar{F}_S 和 \bar{F}_{S_1} 的进行数据筛选. 对于轮式车辆, 选取 \bar{F}_S 中车身主体多普勒较强的多帧回波, 求其能量均值 E_s , 设定 ξ 作为阈值门限, 筛选 \bar{F}_S 中能量大于 ξE_s 的列重组为新的回波矩阵 $F_{\Delta S}$; 对于履带式车辆, 选取 \bar{F}_{S_1} 中车身主体多普勒和上履带微多普勒都比较强的多帧回波, 求其能量均值 E_{s_1} , 设定 ξ_1 作为阈值门限, 筛选 \bar{F}_{S_1} 中能量大于 $\xi_1 E_{s_1}$ 的列重组为新的回波矩阵 $F_{\Delta S_1}$;

Step 4: 对 $F_{\Delta S}$ 和 $F_{\Delta S_1}$ 进行逆傅里叶变换为时域回波矩阵 $IF_{\Delta S}$ 和 $IF_{\Delta S_1}$, 从中分别随机抽取 U 帧 ($U \leq Q$) 组成训练样本的原始数据 $IF_{\Delta S, T}$ 和 $IF_{\Delta S_1, T}$ ($P \times U$), 再对测试样本集使用相同的处理步骤后, 分别随机地抽取 U 帧, 组成测试样本的原始数据 $IF_{\Delta S, t}$ 和 $IF_{\Delta S_1, t}$ (脚标 T 代表 Train, t 代表 test);

Step 5: 对 $IF_{\Delta S, T}$ 和 $IF_{\Delta S_1, T}$ 分别进行 p 阶 AR 模型预测. 每一帧数据通过前后向预测算法得到 p 个 AR 模型复系数, 组成 $1 \times p$ 的向量 a_s 和 a_{s_1} . 为保证信息的完整, 将 a_s 和 a_{s_1} 的实部与虚部提取出来重新组成 $1 \times 2p$ 的向量, 则 U 帧数据将得到系数矩阵 W_s 和 W_{s_1} , W_s 和 W_{s_1} 即为分类器输入的训练样本, 大小均为 $U \times 2p$. 对于测试样本原始数据 $IF_{\Delta S, t}$ 和 $IF_{\Delta S_1, t}$ 进行 p 阶前后向预测, 同样可以得到系数矩阵 Z_s 和 Z_{s_1} , Z_s 和 Z_{s_1} 即为分类器的测试样本.

Step 6: 确定目标回波 AR 模型的最优阶数范围, 在最优阶数范围内对 W_s 和 W_{s_1} , Z_s 和 Z_{s_1} 通过 SVM 或 RVM 完成两类目标的分类.

综上所述, 基于 AR 模型系数的轮式车辆与履带式车辆分类的流程如图 6 所示.

4 实测数据验证

4.1 实测数据预处理

下面分别选取两类车辆目标远离雷达和逼近雷达两种姿态下的实测数据验证本文方法的可行性, 与文




图6 基于AR模型系数的轮式车辆与履带式车辆分类流程图

献[2]为同一批数据. 雷达为毫米波雷达, 到目标的初始距离约为 1.5km, 时域采样率为 64Hz, 一帧数据时长约为 9ms. 表 1 介绍了实测数据的维数和目标速度范围.

表 1 两类车辆目标实测数据集

原始数据		轮式车辆	履带式车辆
训练样本集	远离速度 (m/s)	3.6 ~ 6.2	7.5 ~ 8.8
	样本大小	64 × 4527	64 × 3295
测试样本集 1	逼近速度 (m/s)	2.9 ~ 5.6	2.9 ~ 4.3
	样本大小	64 × 2679	64 × 2713
测试样本集 2	逼近速度 (m/s)	2.4 ~ 5.2	2.4 ~ 4.0
	样本大小	64 × 4807	64 × 4670

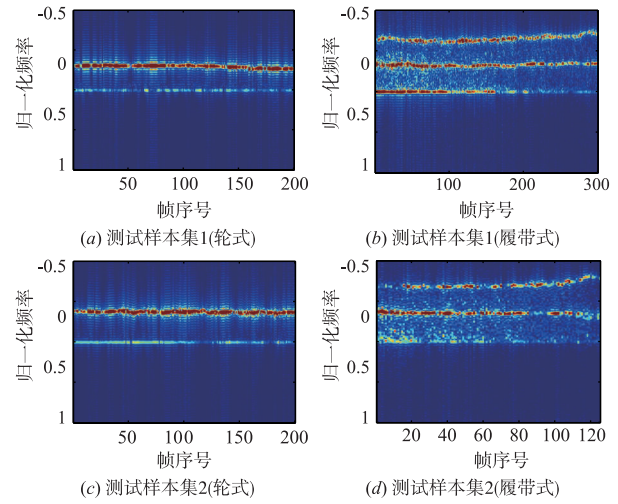


图7 测试样本集1和测试样本集2的车辆目标多帧回波多普勒谱

为保证数据的公平性和识别的可信度, 选取两种实验方案. 实验方案一: 训练样本集 + 测试样本集 1; 实验方案二: 训练样本集 + 测试样本集 2. 图 7 分别为测试样本集 1 和测试样本集 2 的车辆目标多帧回波多普勒谱, 可以看出测试样本集 2 的数据质量略低于测试样本集 1, 尤其履带式车辆的主体回波缺失较多.

首先, 从训练样本集中选取 200 帧目标回波, 对其做 FFT 后采用脉冲抵消技术进行杂波抑制. 图 8 分别为逼近姿态下轮式和履带式车辆杂波抑制后的回波谱图, 可见位于零频附近的地杂波得到抑制. 图 9 为车身多普勒归一化后的回波谱图, 可见两类目标各帧回波的车身主体多普勒频率趋于一致, 在谱图上呈现为一条直线.

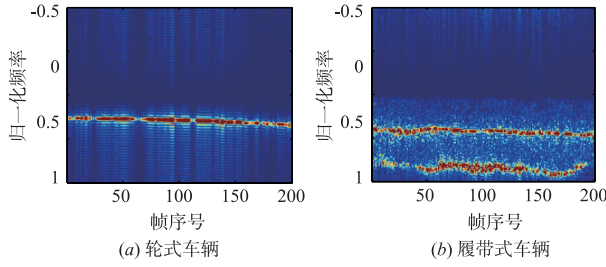


图8 地杂波抑制后车辆目标回波谱图

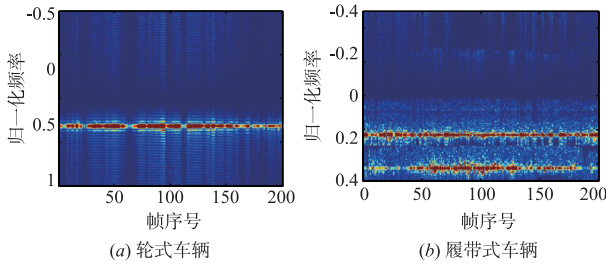


图9 多普勒频率归一化后车辆目标回波谱图

进一步,选取图9(a)中车身多普勒分量较强的第88~93帧回波,求其能量均值 E_s ,设定 $\xi=0.95$ 为阈值门限,从图9(a)中筛选出能量大于 ξE_s 的帧重组为新的回波矩阵,即图10(a);对于履带式车辆,选取图9(b)中车身多普勒和上履带微多普勒都比较强的第115~119帧回波,求其能量均值 E_s ,由于履带式车辆能量相对分散,为兼顾车身多普勒和上履带微多普勒,设定 $\xi_1=0.9$ 作为阈值门限,从图9(b)中筛选能量大于 $\xi_1 E_s$ 的帧重组为新的回波矩阵,即图10(b).此时,数据质量得到明显提高.

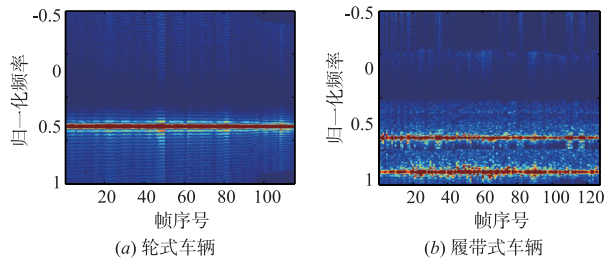


图10 数据筛选后车辆目标回波谱图

4.2 AR 模型阶数判定

以训练样本集1为例,分别采用文献[20]的前向预测方法和前后向预测方法来判定AR模型阶数.经验证发现,前向预测时,轮式车辆回波AR模型的FPE值和AIC值在3阶时即达到最小,而前后向预测时,FPE值和AIC值在7阶时达到最小.可见,对同一目标回波的线性预测,前后向预测比前向预测需要更多的阶数.

对于履带式车辆,在前向预测情况下,FPE值和AIC值在7阶时即达到最小,而前后向预测时,FPE值和AIC值在10阶时达到最小,但总体上履带式车辆回

波所需的AR模型阶数比轮式车辆要大,这是因为相对于轮式车辆,履带式车辆回波信息更加丰富,回波变化相对较大,预测需要的阶数更高.

下面讨论前向预测系数和前后向预测系数的可分性.首先引入谱半径作为参考,由于实际中 $\mathbf{IF}_{\Delta ST}$ 和 $\mathbf{IF}_{\Delta S,T}$ 都不一定是方阵,由系数向量 \mathbf{a}_s 和 \mathbf{a}_{s_1} 可以重构出回波矩阵 $\mathbf{IF}_{\Delta ST}$ 和 $\mathbf{IF}_{\Delta S,T}$,记 p 阶线性预测处理后的预测误差复矩阵为 \mathbf{e}_s ,对 \mathbf{e}_s 作如下变换: $\mathbf{G}_s = \mathbf{e}_s \mathbf{e}_s^H$, \mathbf{e}_s^H 为 \mathbf{e}_s 的共轭转置,此时 \mathbf{G}_s 变为实方阵.在不同阶数下分别求取 \mathbf{G}_s 矩阵的谱半径,即 $\rho_p = \max |\lambda_i|, i=1, 2, \dots, \lambda_i$ 为 \mathbf{G}_s 的特征值.通常谱半径越小,矩阵的收敛性越好,对应的预测误差也越小.

图11分别为不同AR模型阶数下车辆目标预测误差自相关矩阵的谱半径变化图,可见对于同一种车辆,在相同的AR模型阶数下,前后向预测误差自相关矩阵的谱半径更小,预测误差收敛性更好.

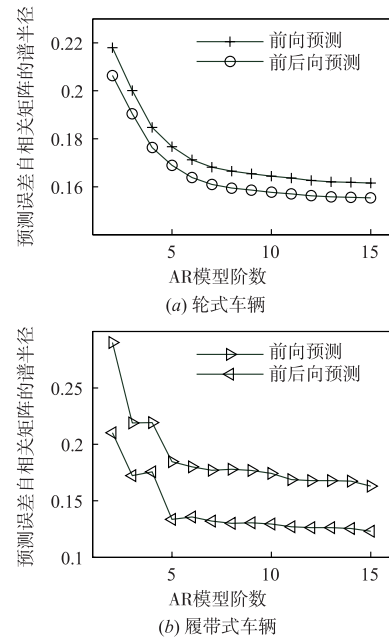


图11 不同AR模型阶数下车辆目标预测误差自相关矩阵的谱半径变化图

再次,可利用距离可分性测度进行评价.构造距离可分性测度为 $J_{ij}^{(n)} = d_{ij}^{(n)} / [\sigma_i^{(n)} + \sigma_j^{(n)}]$,其中 i 和 j 分别代表轮式车辆和履带式车辆, n 表示样本维数,且 $n=2p$, $d_{ij}^{(n)}$ 为样本的平均类间距离,设 $\bar{\mathbf{a}}_i^{(n)}$ 、 $\bar{\mathbf{a}}_j^{(n)}$ 分别表示 n 维系数向量矩阵 $\mathbf{W}_s^{(n)}$ 和 $\mathbf{W}_{s_1}^{(n)}$ 的平均向量,则有 $d_{ij}^{(n)} = \sqrt{\sum_{k=1}^n (\bar{a}_{ik} - \bar{a}_{jk})^2}$,其中 \bar{a}_{ik} 和 \bar{a}_{jk} 为 $\bar{\mathbf{a}}_i^{(n)}$ 、 $\bar{\mathbf{a}}_j^{(n)}$ 的第 k 个元素, $1 \leq k \leq n$. $\sigma_i^{(n)}$ 、 $\sigma_j^{(n)}$ 分别对应两类目标各自样本的标准差, $\sigma_i^{(n)} = \sqrt{\frac{1}{U-1} \cdot \sum_{g=1}^U [\sum_{k=1}^n (a_{gk}^{(i)} - \bar{a}_{ik})^2]}$,其

中 $a_{gk}^{(i)}$ 表示第 i 类目标的 n 维系数向量矩阵 $W_s^{(n)}$ 中的第 g 行第 k 个元素, $1 \leq g \leq U$. $\sigma_j^{(n)}$ 的表达式与 $\sigma_i^{(n)}$ 相似.

可以看出,距离可分性测度反映了两类目标均值向量之间的距离与它们各自标准差之和的比值.显然,类间平均样本距离 $d_{ij}^{(n)}$ 越大,各类特征标准差之和越小,则 $J_{ij}^{(n)}$ 越大,特征的可分性越好.若两类目标为同一目标,则 $d_{ij}^{(n)} = \sigma_i^{(n)} = \sigma_j^{(n)}$, $J_{ij}^{(n)} = 0.5$.


经计算和比较发现,当 AR 模型阶数较低时,前向预测系数特征的类内距离相对较小,类间距离相对较大,可分性测度略优于前后向预测系数特征;随着模型阶数的增加,前后向预测系数特征的类内距离更小,类间距离更大,可分性测度明显优于前向预测系数特征.这是因为前向预测只是从当前数据预测后面的数据,当阶数较低时,预测积累误差相对较小,可分性较好,但随着阶数的增加,如果数据中存在缺失或错误的采样点时,其预测的积累误差将会变大,导致实际预测值偏离真实值较大;而前后向预测方法利用两倍于前向预测方法的数据,从前后两个方向进行预测,即使存在部分不良数据,前向预测难以得到准确的预测值,后向预测中也会得到相应的校正,预测的积累误差相对较小,其系数特征包含的目标特征信息也更加丰富、完整;同时,前向预测系数采用自相关法得到,而前后向预测系数由 Burg 算法基于已有的观测数据计算得到,避免了由有限个数据估计自相关函数的计算及矩阵求逆,在短数据情况下的谱估计比自相关法更加准确、稳健.

为验证方法的分类性能,分别选用支持向量机 (Support Vector Machine, SVM) 和相关向量机 (Relevance Vector Machine, RVM) 作为分类器,核函数选择高斯核函数.从数据筛选后的目标回波中随机抽取 40 帧组成训练样本,对测试样本集 1 和测试样本集 2 按照同样的步骤进行数据预处理,并随机抽取 40 帧作为测试样本.


图 12 为基于方案 1 的分类结果,可见前后向预测系数特征的识别率高于前向预测系数特征,且对于轮式车辆,3 阶线性预测后识别结果趋于平稳,表明分类器达到较为理想的分类模型,履带式车辆识别率相对有所起伏,7 阶后趋于平稳.

图 13 为两种方案下的平均识别率对比结果,可见方案 1 的分类效果优于方案 2,这是因为测试样本集 2 的数据质量低于测试样本集 1 造成的;同时在方案 1 的条件下,RVM 的分类效果优于 SVM,这是因为 RVM 采用贝叶斯方法推理,与 SVM 相比不仅解更为稀疏,而且不需要调整超参数.

图 14 给出前后向预测时间随 AR 模型阶数的变化图,可见 AR 模型阶数越高,前后向预测算法越复杂,耗



(a) 基于前后向预测系数特征的分类效果



(b) 基于前向预测系数特征的分类效果

图12 基于方案1的分类结果




图13 两种方案下的平均识别率对比结果

时越长,但基本在毫秒级,且随阶数的增加运算时间增长较为缓慢.因此,前后向预测是一种运算效率较高的算法,对于小样本分类问题,AR 模型阶数带来的计算量问题基本可以忽略.




图14 前后向预测时间随AR模型阶数的变化图

基于以上分析和仿真实验可以发现,对于小样本

分类问题,AR 模型最优阶数范围可以选择在 7~10 阶,若样本数量巨大,考虑到分类的效率,AR 模型的最优阶数范围可以选择在 3~7 阶.

4.3 算法性能分析

下面在 AR 模型为 10 阶时,对前后向预测算法的分类性能和抗噪性能进行实验验证.表 2 为 10 阶前后向预测后,对训练样本集和测试样本集 1 采用前后向预测系数作为特征的分类结果.同时,与文献[2]的多级小波分解方法和文献[20]的前向预测方法在方案 1 情况下的分类效果进行对比.可见,前后向预测方法的分类效果明显优于文献[2]和文献[20]方法的分类效果.

表 2 分类结果比较

	轮式车辆 识别率	履带式车辆 识别率	平均 识别率
文献[2]方法+SVM	96.52%	91.78%	94.15%
文献[24]方法+SVM	93.14%	94.33%	93.74%
本文方法+SVM	96.63%	94.34%	95.48%
本文方法+RVM	97.26%	95.10%	96.18%

这是因为文献[2]对预处理后的回波采用多级小波分解完成主体多普勒分量和微多普勒分量的分离,再提取各分量能量比和峰值幅度比作为特征,除了分解和计算过程本身带来的误差外,各分量的能量比和峰值幅度比特征虽然也反映了两类目标微多普勒分量的能量和幅度差异,但是将微多普勒分量与多普勒分量严格区分开来,割裂了两者之间的联系,破坏了样本信息的完整性.实际目标回波中的多普勒分量与微多普勒分量在频域是相互叠合在一起的,特别是车轮旋转的微多普勒,以主体多普勒分量为中心对称分布,虽然能量很小,但对实际的分类还存在一定的影响.前后向预测方法的分类效果优于前向预测,前面已进行分析.本文在时域上提取两类车辆目标回波的前后向预测系数特征,实测数据处理是将每帧回波数据全部输入到前后向预测系统,输出结果为前后向预测系数,充分利用了各帧回波每个采样点的全部信息.因此,本文方法提取的前后向预测系数特征的有效性明显高于文献[2]提取的能量比和峰值幅度比特征.

同时,在相同硬件条件下(CPU:Inter R3 2.93 GHz, L2 Cache:2MB,内存:4GB),对本文方法和文献[2]的多级小波分解方法进行运算时间对比,对同样大小(512×40)的轮式车辆回波矩阵和履带式车辆回波矩阵分别进行 10 阶前后向预测,耗时分别为 9.753ms 和 10.982ms,而文献[2]的多级小波分解运算时间分别为 1.247s 和 1.616s,本文方法运算时间比文献[2]方法节省 95% 以上,运算效率优势明显.因此,针对短驻留条件下的车辆目标快速分类,本文方法更加适用.




图 15 10 阶前后向预测时不同信噪比下的分类效果

图 15 给出不同信噪比下基于方案 1 的分类性能,可见随着信噪比的增大,分类精度逐渐提高,在 5 dB 信噪比下,分类精度依然在 80% 以上,验证了本文方法的稳健性.

5 结论

本文基于轮式车辆和履带式车辆的微多普勒特征差异,提出 AR 模型系数的车辆目标分类方法,给出算法流程和具体实现步骤,基于实测数据采用提取出的前后向系数特征,较高精度地完成了两类目标的分类.该方法本质上是将两类目标的微多普勒特征由多普勒域映射为 AR 模型系数组成的集合,以 AR 模型系数差异来表征微多普勒特征差异,计算效率较高,为地面目标分类的实测数据处理提供了参考,为短驻留条件下车辆目标快速分类的工程实现提供了借鉴.

参考文献

- [1] 李开明,等.基于动态字典的卡车目标微动参数估计方法[J].电子学报,2016,44(11):2618-2624.
Li Kai-ming, et al. Micro-motion parameters estimation for truck target based on dynamic dictionary [J]. Acta Electronica Sinica, 2016, 44(11): 2618-2624. (in Chinese)
- [2] 李彦兵,杜兰,刘宏伟,王宝帅.基于微多普勒效应和多级小波分解的轮式履带式车辆分类研究[J].电子与信息学报,2013,35(4):894-900.
Li Yan-bing, Du Lan, Liu Hong-wei, Wang Bao-shuai. Study on classification of wheeled and tracked vehicles based on micro-Doppler effect and multilevel wavelet decomposition [J]. Journal of Electronics & Information Technology, 2013, 35(4): 894-900. (in Chinese)
- [3] 张河.探测与识别技术[M].北京:北京理工大学出版社.2003.1-8.
- [4] 聂伟荣.多传感器探测与控制网络技术—地面运动目标震动信号探测与识别[D].南京:南京理工大学,2001.
Nie Wei-rong. Detecting and controlling network technology with multi-sensor system-micro-seismic signals detecting and identification of target moving on the ground [D].

- Nanjing: Nanjing University of Science and Technology, 2001. (in Chinese)
- [5] 何光林,等. 基于噪声特征的地震动信号目标预警和识别算法研究[J]. 北京理工大学学报,2014,34(1):64-67.
He Guang-lin, et al. Research on early-warning and target identification algorithm of seismic signal based on characteristics of noise [J]. Transactions of Beijing Institute of Technology, 2014, 34(1): 64-67. (in Chinese)
- [6] 林岳松,陈琳,等. 基于数据驱动的信息融合及其在车辆声辨识中的应用[J]. 电子与信息学报,2011,33(9):2158-2163.
Lin Yue-song, Chen Lin, et al. A data-driven fusion and its application to acoustic vehicle classification [J]. Journal of Electronics & Information Technology, 2011, 33(9): 2158-2163. (in Chinese)
- [7] Jinhui Lan, Yong Xiang, et al. Vehicle detection and classification by measuring and processing magnetic signal [J]. Measurement, 2011, 44(1): 174-180.
- [8] 宣益民,韩玉阁. 地面目标与背景的红外特征[M]. 北京:国防工业出版社,2004.
- [9] Ruohong Huan, Yun Pan. Target recognition for multi-aspect SAR images with fusion strategies [J]. Progress in Electromagnetics Research, 2013, 134: 267-288.
- [10] 代大海. 极化雷达成像及目标特征提取研究[D]. 长沙:国防科技大学,2008.
Dai Da-hai. Study on polarimetric radar imaging and target feature extraction [D]. Changsha: The National University of Defense Technology, 2008. (in Chinese)
- [11] 陈晓清,等. 利用奇异值特征的激光成像雷达目标识别[J]. 红外与激光工程,2011,40(9):1801-1805.
Chen Xiao-qing, et al. Target recognition using singular value feature for laser imaging radar [J]. Infrared & Laser Engineering, 2011, 40(9): 1801-1805. (in Chinese)
- [12] Alessandro Mecocci. Moving object recognition and classification in external environments [J]. Signal Processing, 1989, 18(2): 183-194.
- [13] 廖东平. 支持向量机方法及其在机载毫米波雷达目标识别中的应用研究[D]. 长沙:国防科技大学,2006.
Liao Dong-ping. Study on support vector machine method and its application in target recognition for airborne MMW radar [D]. Changsha: The National University of Defense Technology, 2006. (in Chinese)
- [14] Stove A G, Sykes S R. A Doppler-based automatic target classifier for a battlefield surveillance radar [A]. Proceedings of IEEE International Conference on Radar [C]. Edinburgh, UK, 2002. 419-423.
- [15] 冀振元,李晨雷,等. 支持向量机在车辆目标识别中的应用[J]. 系统工程与电子技术,2010,32(2):284-286.
Ji Zhen-yuan, Li Chen-lei, et al. Application of SVM in recognition of vehicles [J]. Systems Engineering and Electronics, 2010, 32(2): 284-286. (in Chinese)
- [16] V C Chen, F Y Li, S-S Ho, et al. Micro-Doppler effect in radar: Phenomenon, model and simulation study [J]. IEEE Transactions on AES, 2006, 42(1): 2-21.
- [17] 张群,罗迎. 雷达目标微多普勒效应[M]. 国防工业出版社,2013.
- [18] Smith G E, Woodbridge K, et al. Radar micro-Doppler signature classification using dynamic time warping [J]. IEEE Transactions on Aerospace and Electronic Systems, 2010, 46(3): 1078-1096.
- [19] 黄健,李欣,等. 基于微多普勒特征的坦克目标参数估计与身份识别[J]. 电子与信息学报,2010,32(5):1050-1055.
Huang Jian, Li Xin, et al. Micro-Doppler features based parameter estimation and identification of tank [J]. Journal of Electronics & Information Technology, 2010, 32(5): 1050-1055. (in Chinese)
- [20] Rios Jesus Javier, Youngwook Kim. Application of linear predictive coding for human activity classification based on micro-Doppler signatures [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(10): 1831-1834.
- [21] 孙志强,陈延平. 基于 Burg 法 AR 模型谱估计的涡街流量计旋涡脱落频率提取[J]. 中南大学学报(自然科学版),2013,44(04):1684-1688.
Sun Zhi-qiang, Chen Yan-ping. Extraction of vortex flowmeter frequency by Burg algorithm based AR model spectral estimation [J]. Journal of Central South University (Science and Technology), 2013, 44(04): 1684-1688. (in Chinese)
- [22] 丁玉美,阔永红,高新波. 数字信号处理-时域离散随机信号处理[M]. 西安:西安电子科技大学出版社,2002.

作者简介



李开明 男,1982年12月生,山西应县人。分别于2009年和2016年于空军工程大学获工学硕士学位和工学博士学位。现为空军工程大学信息与导航学院讲师、在站博士后。目前主要从事雷达成像及目标识别领域的研究工作。
E-mail: likaiming1982@163.com



张群 男,1964年11月生,陕西合阳人。现为空军工程大学信息与导航学院教授,博士生导师。发表论文400余篇,其中SCI、EI检索200余篇,出版中英文专著各1部。研究方向:雷达信号处理、雷达成像及电子对抗。
E-mail: afeuzq@163.com