



中文核心期刊

中国科技核心期刊

ISSN 1672-2337

CN 34-1264/TN

雷达科学与技术

RADAR SCIENCE AND TECHNOLOGY

2026 1

第24卷 第1期 Vol. 24 No.1

ISSN 1672-2337



中国电子科技集团公司第三十八研究所 主办



《中文核心期刊要目总览》2023年版入编通知

《雷达科学与技术》主编先生/女士：

我们谨此郑重通知：依据文献计量学的原理和方法，经研究人员对相关文献的检索、统计和分析，以及学科专家评审，贵刊《雷达科学与技术》入编《中文核心期刊要目总览》2023年版（即第10版）之电子技术、通信技术类的核心期刊。

《中文核心期刊要目总览》2023年版从2021年10月开始研究，研究工作由北京大学图书馆主持，共 32 个单位的 148 位专家和工作人员参加了本项研究工作，全国各地 9473 位学科专家参加了核心期刊表的评审工作。经过定量筛选和专家定性评审，从我国正在出版的中文期刊中评选出 1987 种核心期刊。


评选核心期刊的工作是运用科学方法对各种刊物在一定时期内所刊载论文的学术水平和学术影响力进行综合评价的一种科研活动。该研究成果只是一种参考工具书，主要是为图书情报界、出版界等需要对期刊进行评价的用户提供参考，例如为各图书情报部门的中文期刊采购和读者导读服务提供参考帮助等，不应作为评价标准。谨此说明。

顺颂

撰安

编号：2023-J11272

《中文核心期刊要目总览》
2023年版编委会



《雷达科学与技术》 编辑委员会

顾问 张履谦(院士) 王越(院士)
张锡祥(院士) 毛二可(院士)
张光义(院士) 刘永坦(院士)
郭桂蓉(院士) 贲德(院士)
段宝岩(院士) 何友(院士)
吴一戎(院士) 王永良(院士)
苏东林(院士)
Mark E. Davis(美) Hugh Griffiths(英)
Marc Lesturgie(法) Don Sinnott(澳)
Hermann Rohling(德)

编辑委员会

主任 吴剑旗(院士)

常务副主任 张成伟 杨建宇

副主任 刘宏伟 张修社 马林 谭贤四
洪文 杨小鹏 位寅生 张春城
余继周 朱庆明 杜兰

委员 (以姓氏笔画为序)

丁东阳 万显荣 万海东 马汉清
王壮 王岩 王勇 王璐
王露 王咸鹏 毛云祥 仇晓兰
凤宏晓 孔令讲 龙伟军 史治国
朱岱寅 刘丹 刘伟 刘杰
刘涛 刘一民 刘宁波 江凯
孙合敏 苏洪涛 李刚 李明
李品 李勇 李大圣 李天成
李均阁 李健兵 李海彬 杨吟华
吴文 宋思盛 张帆 张寅
张建明 张剑云 张海君 张慧玲
张增辉 陆炫宇 陈渤 陈小龙
陈晓辉 陈曾平 武国宁 武俊杰
明峰 罗迎 罗健 金林
金添 周共健 郑纪彬 赵婵娟
查林 洪弘 秦琨 袁子雄
莫修辞 夏正欢 顾杰 钱君辉
倪国新 徐丰 徐绍剑 徐晓天
高红卫 陶然 黄平平 黄金杰
黄钰林 盛景泰 董云龙 董智文
景凯 程强 靳学明 雷鹏
蔡兴雨 熊朝华

主编 吴剑旗(院士)

执行主编 苏纪煌

责任编辑 王莉

编辑部 潘玉静 黄穗

目次

BWRadarDataset-1.0:多波段多模态雷达探测感知数据集

…… 张转花,靳俊峰,常沛,何洋洋,汪振亚,侯其立,李玉景,等(1)

基于去相关无偏转换量测的外辐射源雷达跟踪算法

…… 陈书恒,朱倪瑶,王海鹏,张鑫(15)

基于混合策略改进DBO的多无人机协同干扰策略

…… 李家强,喻庞泽,李淑君,陈金立,姚昌华(22)

基于降维累积量和矩阵重构的相干DOA估计

…… 刘宁庄,侯志凯,符渭波,田海波(31)

融合海洋环境要素的多尺度海面电磁散射建模

…… 邵学辉,冯杨楠,薛冰,王伟,刘鹰(42)

一种基于判别投影特征提取的杂波点迹滤除方法

…… 汪晋,苏洪涛,汪圣利,田强(52)

基于Roberts直线表示的三维空间约束航迹起始算法

…… 邵晗星,郑纪彬,白艳雯,葛页,刘伯阳,张少峰,魏小丹(62)

基于多尺度特征匹配的小样本雷达无人机识别

…… 孙延鹏,石增辉,屈乐乐(74)

融合光学信息的阵列干涉SAR三维成像

…… 张月皎,焦泽坤,李若明(83)

一种基于最邻近相似度模型的捷变雷达辐射源识别方法

…… 夏冬玉,贾军帅,张玉,董华智(94)

基于航迹特征原型选择的军民船双分支融合识别

…… 张鑫,王海斌,莫嘉倩,史华莹,刘钢(99)

基于互补波形设计的频谱弥散干扰抑制方法

…… 杨贤(110)

Radar Science and Technology

(Bimonthly)

Vol.24 No.1

February 2026

CONTENTS

BWRadarDataset-1.0: Multi-Band Multi-Mode Radar Dataset for Detection and Sensing	
.....	ZHANG Zhuanhua, JIN Junfeng, CHANG Pei, HE Yangyang, WANG Zhenya, HOU Qili, LI Yujing, et al(1)
External Radiation Source Passive Radar Tracking Algorithm Based on Decorrelated Unbiased Converted Measurement	 CHEN Shuheng, ZHU Niyao, WANG Haipeng, ZHANG Xin(15)
Multi-UAV Cooperative Jamming Strategy Based on Hybrid Strategy Improved DBO	 LI Jiaqiang, YU Pangze, LI Shujun, CHEN Jinli, YAO Changhua(22)
Coherent DOA Estimation Based on Reduced-Dimensional Cumulants and Matrix Reconstruction	 LIU Ningzhuang, HOU Zhikai, FU Weibo, TIAN Haibo(31)
Multi-Scale Sea Surface Electromagnetic Scattering Modeling Integrating Marine Environmental Elements	 SHAO Xuehui, FENG Yangnan, XUE Bing, WANG Wei, LIU Ying(42)
A Feature Extraction Method Based on Discriminant Projections for Clutter Plot Filtering	 WANG Jin, SU Hongtao, WANG Shengli, TIAN Qiang(52)
A Three-Dimensional Space-Constrained Track Initiation Algorithm Based on Roberts' Straight-Line Representation	 SHAO Hanxing, ZHENG Jibin, BAI Yanwen, GE Ye, LIU Boyang, ZHANG Shaofeng, WEI Xiaodan(62)
Few-Shot Radar UAV Recognition Based on Multi-Scale Feature Matching	 SUN Yanpeng, SHI Zenghui, QU Lele(74)
3D Imaging of Array Interferometric SAR with Integrated Optical Information	 ZHANG Yuejiao, JIAO Zekun, LI Ruoming(83)
An Agile Radar Emitter Identification Method Based on the Nearest Neighbor Similarity Model	 XIA Dongyu, JIA Junshuai, ZHANG Yu, DONG Huazhi(94)
Dual-Branch Fusion Recognition of Military and Civilian Vessels Based on Trajectory Feature Prototype Selection	 ZHANG Xin, WANG Haibin, MO Jiaqian, SHI Huaying, LIU Gang(99)
Smeared Spectrum Jamming Suppression Method Based on Complementary Waveform Design	 YANG Xian(110)

BWRadarDataset-1.0: 多波段多模态雷达探测感知数据集

张转花^{1,2}, 靳俊峰^{1,2}, 常沛^{1,2}, 何洋洋^{1,2}, 汪振亚^{1,2}, 侯其立^{1,2}, 李玉景^{1,2}, 郝慧军^{1,2},
曾怡^{1,2}, 夏勇^{1,2}, 商国军^{1,2}, 许涛^{1,2}, 任伟杰^{1,2}, 雷鸣^{1,2}, 王歆远^{1,2}, 寿博^{1,2}, 邓丽颖^{1,2},
任乐乐^{1,2}, 窦曼莉^{1,2}, 杨利红^{1,2}, 张琦璐^{1,2}, 李伟^{1,2}, 牛蕾^{1,2}, 林晓斌^{1,2}, 张志成^{1,2}

(1. 中国电子科技集团公司第三十八研究所, 安徽合肥 230088;

2. 雷达探测感知全国重点实验室, 安徽合肥 230088)

摘要: 雷达探测感知技术飞速发展浪潮下高质量数据集在算法创新、模型训练与性能验证中发挥着重要作用。当前,深度学习等数据驱动方法已成为提升雷达在检测、跟踪、识别、干扰及合成孔径雷达(SAR)成像等核心任务性能的关键。然而,现有的数据集大多基于仿真生成,与真实电磁环境存在差异,泛化能力受限,并且现有的数据集仅针对单一功能,例仅有检测或SAR,缺乏系统性,难以支撑探测感知处理的一体化研究。针对这一空白,本文公开了一套完整的雷达检测跟踪识别一体化数据集。该数据集源于典型的实测场景,涵盖了信号处理、目标跟踪、精细识别、复合干扰以及高分辨率SAR图像的多波段、多模态数据,真实反映复杂环境下雷达信号的传播特性与目标特性。进一步,本文对数据集中的关键特征进行了系统性提取与分析,为不同任务的算法研究与性能评估提供了标准化的特征输入,为研究雷达智能化信号与信息处理提供了坚实的基础。

关键词: 雷达探测; 公开数据集; 特征提取; 目标检测; 目标跟踪; 目标识别; 有源干扰; SAR图像; 特征分析

中图分类号: TN957

文献标志码: A

文章编号: 1672-2337(2026)01-0001-14

引用格式: 张转花,靳俊峰,常沛,等. BWRadarDataset-1.0: 多波段多模态雷达探测感知数据集[J]. 雷达科学与技术, 2026, 24(1): 1-14.

ZHANG Zhuanhua, JIN Junfeng, CHANG Pei, et al. BWRadarDataset-1.0: Multi-Band Multi-Mode Radar Dataset for Detection and Sensing[J]. Radar Science and Technology, 2026, 24(1): 1-14.

BWRadarDataset-1.0: Multi-Band Multi-Mode Radar Dataset for Detection and Sensing

ZHANG Zhuanhua^{1,2}, JIN Junfeng^{1,2}, CHANG Pei^{1,2}, HE Yangyang^{1,2}, WANG Zhenya^{1,2}, HOU Qili^{1,2}, LI Yujing^{1,2}, HAO Huijun^{1,2},
ZENG Yi^{1,2}, XIA Yong^{1,2}, SHANG Guojun^{1,2}, XU Tao^{1,2}, REN Weijie^{1,2}, LEI Ming^{1,2}, WANG Xinyuan^{1,2}, SHOU Bo^{1,2}, DENG Liying^{1,2},
REN Lele^{1,2}, DOU Manli^{1,2}, YANG Lihong^{1,2}, ZHANG Qijun^{1,2}, LI Wei^{1,2}, NIU Lei^{1,2}, LIN Xiaobin^{1,2}, ZHANG Zhicheng^{1,2}

(1. The 38th Research Institute of China Electronics Technology Group Corporation, Hefei 230088, China;

2. National Key Laboratory of Radar Detection and Sensing, Hefei 230088, China)

Abstract: With the rapid development of radar detection and sensing technology, high-quality datasets play a critical role in algorithm innovation, model training, and performance verification. Nowadays, data-driven approaches such as deep learning have become the key in improving radar performance including detection, tracking, recognition, jamming and SAR. However, most of the existing datasets are generated by simulation, which is different from the real electromagnetic environment, and the generalization ability is limited. Moreover, these datasets are often designed for single mode, such as detection or SAR, and lack of systematicness, which is difficult to support the integrated research of detection, sensing and processing. In response to this gap, this paper introduces a comprehensive integrated dataset for radar detection, tracking and recognition. The dataset is derived from typical measured scenes, covering multi-band and multi-mode data, which includes signal processing, target tracking, fine-grained recognition, compound jamming and high-resolution SAR imaging, which truly reflects the propagation characteristics and target characteristics of radar sig-

nals in complex environments. Furthermore, this paper conducts a systematic extraction and analysis of key features within the dataset, providing standardized feature input for algorithm development and performance evaluation in different tasks. This work contributes to provide a solid foundation for research in intelligent radar signal and information processing.

Key words: radar detection; publicly available datasets; feature extraction; target detection; target tracking; target recognition; active jamming; SAR image; feature analysis

0 引言

现代雷达探测感知技术正面临复杂电磁环境与多样化任务的严峻挑战,其发展路径已从传统信号处理模式转向与人工智能深度结合的智能感知新范式^[1-4]。这一转换使高质量数据成为驱动算法创新的核心要素,而雷达系统固有的多波段特性、多模态处理及复杂电磁效应,对训练数据的规模、真实性与系统性提出了更高要求^[5]。为打通从智能模型研发到装备实战应用的关键路径,构建多波段、多模态雷达探测感知数据集势在必行。

雷达目标检测数据集方面,宋志勇等人^[6]发布了雷达固定翼无人机弱小目标检测跟踪数据集。关键等人^[7]发布了不同极化和不同海况下的海上目标散射特性数据,支撑“雷达对海探测数据共享计划(SDRDSP)”。陈小龙等人^[8-9]和林钱强等人^[10]公开了无人机等低慢小探测数据集。刘宁波等人^[11]构建了涵盖多种类型海上目标的多源观测数据集。程永强等人^[12]发布了一套地杂波背景下雷达低慢小无人机探测数据集(LSS-Ku-1.0)。

目标跟踪数据集方面,回丙伟等人^[13]构建了低空飞行固定机翼无人机目标的数据集,为精确制导和红外目标探测提供了基础数据。伍琼燕等人^[14]构建了小汽车、卡车、公交车和摩托车4种车辆类别的数据集VeDT-MSS,用以城市和乡村监控。刘丽华等人^[15]公布了2D雷达与侦察传感器舰船目标跟踪数据集。肖云等人^[16]以搭载混合传感器的高空无人机为平台,对拍摄的可见光和红外多模态视频进行配准,构建了多模态目标跟踪数据集HiAI。

目标识别数据集方面,Sun等人^[17]构建了遥感图像飞机目标识别数据集FAIR1M,涵盖了波音、空客、C919等多种民航目标。Haroon等人^[18]公开了多种尺寸目标数据集SMID,包含车辆、飞机、船只等目标类型。禹文奇等人^[19]发布了多种军用飞

机目标识别数据集MAR20,包含战斗机、轰炸机、运输机、预警机、攻击机等多种军用目标。任俊宇等人^[20]公开了无人机射频信号数据集DroneRFb-DIR。

雷达干扰数据集方面,刘国满等人^[21]构建了涵盖8种干扰样式的时频分布数据。郭立民等人^[22]借助两个模拟干扰机设计了复合干扰信号,通过有机组合多个单一干扰信号构建了加性复合干扰。李佳浩等人^[23]基于双射线传播模型通信信道构建了无人机通信干扰数据集。郭文杰等人^[24]设计了6种经典单一和6种复合样式的雷达有源干扰数据集。陈思伟等人^[25]基于MiniSAR实测数据和仿真数据构建了包含5类干扰样式的有源干扰数据集。王佳祥等人^[26]基于信号建模仿真技术构建了包含3种干扰信号图像的数据集。

SAR图像处理数据集方面,李健伟等人^[27]首次给出了SAR图像舰船检测数据集(SAR Ship Detection Dataset, SSDD),填补了SAR图像舰船目标数据集的空白。徐从安等人^[28]公布了SAR舰船斜框检测数据集(RSDD-SAR)。为了验证层析合成孔径雷达(Tomographic Synthetic Aperture Radar, TomoSAR)方法,仇晓兰等人公开了SARMV3D-1.0^[29]和SARMV3D-2.0^[30]数据集,Chen等人^[31]公布了GOTCHA数据集,Vasile等人^[32]公布了TropiSAR数据集,Sun等人^[33]公开了BioSAR数据集,焦润之等人^[34]公开了3DSARBuSim 1.0数据集。金燕等人^[35]给出了多维度SAR多波段分类数据集(MPOL-SAR-1.0)。郑乃榕等人^[36]发布了高分辨率机载多维度SAR地物分类数据集AIR-MDSAR-Map。王汝意等人^[37]构建了多角度SAR数据集。雷禹等人^[38]构建了宽幅SAR大型民用舰船和军事舰船目标数据集。王智睿等人^[39]公布了多极化SAR多地物类别数据集(AIR-PolSAR-Seg-2.0)。

上述数据集在雷达探测感知领域获得了广泛应用。然而,该领域的数据集建设仍存在显著瓶颈,严重制约了先进算法向实战化装备的有效转

换,表现在:1)现有仿真数据集普遍存在真实性不足的问题。目前多数研究依赖于纯数学仿真或简化的电磁模型生成数据,未能充分复现复杂实战环境中的电磁传播特性、地海杂波背景以及雷达装备本身的非线性效应。这种理想化的数据与实际装备采集的回波在统计特性、误差结构和干扰样式上存在较大的差异,导致在其上训练和验证的算法大相径庭。当算法从仿真环境迁移至实际装备时,性能往往出现显著衰退,使得仿真阶段的验证结果不可靠,极大增加了算法工程化应用的风险与成本。2)已发布的数据集功能单一,缺乏覆盖全链路的系统性数据。公开的数据集多为针对特定任务而设计,例如仅为目标检测、仅为跟踪或仅为SAR成像提供片段式数据。这些“孤岛式”的数据集无法支撑从信号级处理、目标检测、点航迹关联、目标跟踪到目标识别与干扰对抗的完整雷达探测感知链路式的算法研发与验证。特别是针对电子对抗场景,公开的、高质量的干扰数据集尤为匮乏。这种数据割裂的现状,使得研究人员难以评估算法在完整任务链中的协同性能和鲁棒性,也无法系统性研究“检测-跟踪-识别-抗干扰-SAR成像”一体化等前沿课题。

为了弥补这一空白,本文的主要工作如下:1)发布了包含五大核心功能的完整数据集,具体包括:雷达目标检测数据集,包括单个脉冲脉压后的原始回波数据、回波相关参数信息和目标标签信息;雷达目标跟踪数据集,包含多批目标在杂波环境下的点迹数据和航迹信息;雷达目标识别数据集,包含8型民航飞机脉压后窄带高重频数据;雷达有源干扰数据集,包含脉压前原始回波、复合干扰类型、位置和目标位置标签;SAR图像数据集,包含舰船、飞机、桥梁及油罐4类目标的图像文件和标签文件。2)提取了数据集多维特征信息:除原始回波数据外,还提供了回波参数信息(时间信息、波位编号、距离单元的个数、脉冲个数)、目标运动参数(位置、速度、加速度)以及真值标签(目标类型、复合干扰类型)。3)分析了数据集的深层特征分布:通过绘制目标多普勒谱图、干扰信号时频图谱、目标跟踪航迹以及SAR图像指标等高信息图表,将多维特征进行直观的

量化表达,不仅验证了数据集的内在一致性,更为研究者提供了可直观用于算法性能评估与对比分析的基准。

1 数据集构建

1.1 数据集基础信息

多波段多模态雷达探测感知数据集由5部分组成:雷达目标检测数据、雷达目标跟踪数据、雷达目标识别数据、雷达有源干扰数据和SAR图像数据。雷达目标检测数据为脉压后的IQ数据,共计8 000条,每条数据都包含目标位置标签;雷达目标跟踪数据共计2 088帧,每帧包含有目标点和杂波点;雷达目标识别数据为脉压后窄带高重频数据,共计3 519条,涵盖8型民航飞机;雷达有源干扰数据为脉压前单脉冲数据,共计10 000条,每条数据包含有目标和干扰,共计8种干扰样式;SAR图像数据为切片数据,共计10 000条,每条数据包含图像切片和目标标签,涵盖舰船、飞机、桥梁及油罐4类目标。雷达探测感知数据集基础信息如表1所示。

表1 多波段多模态雷达探测感知数据集基础信息

数据类型	波段	数据规模	数据组成
雷达目标检测数据	S波段	8 000条	脉压后的IQ数据,目标位置标签
雷达目标跟踪数据	S波段	2 088帧	民航点迹、杂波点迹、281条民航航迹
雷达目标识别数据	S波段	3 519条	脉压后窄带高重频数据,8型民航飞机
雷达有源干扰数据	L波段	10 000条	脉压前单脉冲数据,8种干扰样式
SAR图像数据	C波段	10 000条	图像切片,目标标签,4类目标

数据格式命名如下:

1)雷达目标检测数据。提取脉压后的IQ数据,每条数据的规模为脉冲数×距离单元数,目标检测数据命名为dataEcho_波位编号.mat(例:dataEcho6.mat)。

2)雷达目标跟踪数据。取出采集时间段内的点迹和航迹数据,点迹命名方式为:帧序号_当前帧起始时间.csv(例:1087_10858.csv),航迹命名方式:R_航迹批号(例:R_64.csv),R表示航迹(Track)。

3) 雷达目标识别数据。将I与Q两个物理通道的信号,分别映射为复数的实部与虚部,构建窄带高重频数据。目标识别数据命名为民航飞机型号名(例:A319-115)。

4) 雷达有源干扰数据。通过将噪声数据、干扰数据与目标回波数据相融合,构建了本干扰数据集。脉冲回波数据存储于文件outData.mat,数据头参数存储于文件outPara.mat。

5) SAR图像数据。对商遥卫星数据进行切片处理,获得图像切片和目标标签文件,图像切片命名方式为:0序号.jpg(例:0235.jpg),标签命名方式为:对应图像切片同名的.txt文件(例:0235.txt)。

1.2 雷达目标检测数据

本数据集旨在提供噪声背景下的目标脉压后回波数据,用于信号检测。其中,距离分辨率为25 m,重复周期为5 600 μ s,距离单元数为1 000,脉冲数为5。共计8 000条,每条数据为脉压后的IQ数据,其形式为复数,规模为脉冲数 $\times$ 距离单元数。

目标检测数据集命名为:dataEcho波位编号.mat(例:dataEcho6.mat,6表示波位编号)。每个.mat文件包含data_echo和Label_echo两个文件,data_echo存储脉压后的IQ数据,Label_echo存储目标所在距离单元的标签。雷达目标检测数据集文件名如表2所示。

表2 雷达目标检测数据集

检测数据文件名
➤dataEcho1.mat(dataEcho波位编号)
➤dataEcho2.mat
➤.....
➤dataEcho8000.mat

1.3 雷达目标跟踪数据

本数据集专为目标起始、关联与跟踪任务而设计。它提供了2 088帧包含杂波的点迹数据,以及281批目标航迹数据。点迹数据命名方式为,帧序号_当前帧起始时间.csv(例:1087_10858.csv,1087表示帧序号,10858表示当前帧起始时间,单位:s)。点迹数据集文件名如表3所示。

表3 雷达目标跟踪点迹数据集

点迹数据文件名
➤1_0.csv(帧序号_当前帧起始时间)
➤2_10.csv
.....
➤2088_20862.csv

点迹数据的列定义依次为:点迹序列号、点迹时间(单位:ms)、距离(单位:m)、方位角(单位:°)、俯仰角(单位:°)、强度(无量纲量,范围:0~1)。

航迹数据命名方式为,R_航迹批号(例:R_64.csv,R表示航迹,64表示目标航迹批号)。航迹数据集文件名如表4所示。航迹数据中仅记录了与之关联的点迹序列号,数据处理系统以此序列号列表为索引,通过查询点迹数据集,可获取该航迹所对应的全部点迹详细信息。

表4 雷达目标跟踪航迹数据集

航迹数据文件名
➤R_1.csv(航迹_目标航迹批号)
➤R_2.csv
➤.....
➤R_281.csv

1.4 雷达目标识别数据

为支持目标识别算法的验证与评估,本研究提供了基于S波段雷达采集的民航飞机观测数据集。数据形式为脉压后的窄带高重频信号,重频为4 000 Hz。数据集涵盖了8型典型的民航飞机机型,表5列出了该数据集所包含的数据名称与对应的数据规模。其中,数据名称表示民航飞机型号。

表5 雷达目标识别窄带高重频数据集

序号	数据名称	数据规模(条)
1	A319-115	388
2	A319-133	367
3	A320-214	467
4	A320-232	505
5	A321-231	355
6	A330-243E	196
7	B737-700	163
8	B737-800	1 078

每个目标识别数据集以行为单位进行组织,其中每一行代表一条窄带高重频数据。每条窄带高重频数据以复数形式表示,其中I与Q两个物理通道的信号,分别映射为复数的实部与虚部。

1.5 雷达有源干扰数据

为服务于干扰技术的发展与应用,本研究提供了包含目标回波信号与压制类、灵巧类、欺骗类干扰信号的数据集。该数据集由10 000条脉压前单脉冲数据样本组成,划分为训练集和测试集。其中,训练集有8 000条,测试集有2 000条。每条数据包含的干扰样式为1~3种,目标个数为1~3个。

干扰数据集存储在“outData.mat”和“outPara.mat”两个文件中,“outData.mat”文件存储脉冲回波数据,每行数据表示一条单脉冲数据的基带IQ数据,目标回波信号为线性调频信号。“outPara.mat”文件存储数据头参数。文件“outData.mat”的每一行与文件“outPara.mat”的每一行一一对应。雷达有源干扰数据集的文件名如表6所示。

表6 雷达有源干扰数据集

雷达干扰数据文件名
➤train(训练集目录)
outData.mat
outPara.mat
➤test(测试集目录)
outData.mat
outPara.mat

“outPara.mat”数据头参数文件有24列,每列代表的含义如表7所示。为精简表格,将内容相似的三行合并为一行展示,其列号以数字+顿号的形式表示。表中列号13,17,21的取值说明为:2-瞄准式噪声干扰,3-阻塞式噪声干扰,4-扫频式噪声干扰,5-噪声卷积干扰,6-噪声乘积干扰,7-间歇采样转发干扰,8-频谱弥散干扰,9-全脉冲转发干扰。

1.6 雷达SAR图像数据

本数据集旨在为SAR图像检测算法提供基准测试数据。从民用商遥卫星图像数据中,挑选出

表7 雷达有源干扰数据头

列号	数据头含义	取值说明
1、2、3	采样率,脉宽,带宽	单位:Hz;单位:s;单位:Hz
4、7、10	目标1、2、3起始位置	取值:[1,15 000],无量纲,值为0表示没有目标
5、8、11	目标1、2、3结束位置	取值:[1,15 000],无量纲,值为0表示没有目标
6、9、12	目标1、2、3信噪比	单位:dB,该值仅在目标存在时有效
13、17、21	干扰1、2、3样式	取值:1~9,1表示没有干扰
14、18、22	干扰1、2、3起始位置	取值:[1,15 000],无量纲,值为0表示没有干扰
15、19、23	干扰1、2、3结束位置	取值:[1,15 000],无量纲,值为0表示没有干扰
16、20、24	干扰1、2、3干噪比	单位:dB,该值仅在干扰存在时有效

含有舰船、飞机、桥梁及油罐4类目标的影像图。通过影像标注软件对图像中的目标利用矩形框标签进行清洗标注,获取原图目标标签文件。基于原图和对应的目标标签文件,裁剪生成包含舰船、飞机、桥梁及油罐4类目标的图像切片,以及与之对应的目标标签文件。其中,舰船有13 038只,飞机有5 699架,桥梁有551架,油罐有919个。

SAR图像数据集存储在JPEGImage图像文件夹和Annotations标签文件夹,每个文件夹内包含10 000条数据。JPEGImage图像文件夹存储的图像格式为.jpg,其为三通道灰度图像,24位深JPG,切片尺寸为256×256像素,部分桥梁切片为2 048×2 048像素。SAR图像数据集的文件名如表8所示。

表8 SAR图像数据集

SAR图像数据文件名
➤01.jpg(0序号)
➤02.jpg
.....
➤010000.jpg

Annotations标签文件夹存储标签文件.txt,如表9所示。标签数据文件中,每个目标实例独占一行,每行数据依次包含该目标的类别标识及其位置参数。其中,目标类别(记class_id)有:{0-舰船;

1-飞机;2-桥梁;3-油罐},位置参数由归一化的目标中心点 x 轴坐标(记 x_center)、归一化的目标中心点 y 轴坐标(记 y_center)、归一化的目标宽度(记 $width$)及归一化的目标高度(记 $height$)组成,符合YOLO数据标签格式。

表9 SAR图像数据标签文件

SAR图像数据标签文件名
➤01.txt(0序号)
➤02. txt
.....
➤010000. txt

2 数据集多域多维特性

2.1 雷达目标检测数据特征提取

从原始回波数据中有效提取目标信息是实现精确检测的核心。距离-幅度与多普勒谱图作为两种基础且强大的中间数据表征,分别从空间维和频率维揭示了目标的物理特性,为从噪声与杂波背景中分离出有效的目标特征提供依据。

距离单元幅度特征是目标在雷达径向上散射能量分布的一维快照,量化了目标在何处及其散射强度如何。其形成原理根植于雷达的测距与脉冲压缩理论。雷达发射信号 $s_t(t)$ 在遇到目标后产生回波 $s_r(t)$ 。为实现高分辨率测距,现代雷达普遍发射线性调频信号。脉压后的信号为 $y(t)$,其表达式为

$$y(t) = \int s_r(u) \cdot h(t-u) du = \int s_r(u) \cdot s_r^*(u-t) du \quad (1)$$

该表达式实现了信号能量的时域聚焦。经过采样后, $y(t)$ 被离散化为一系列按时间先后(即距离远近)排列的距离单元。距离单元幅度特征定义为这些距离单元上所对应的信号包络幅度的集合 $|y[n]|$,其中, n 为距离门索引。

多普勒谱图是脉冲多普勒雷达对目标速度维信息进行频谱分析的核心表征,其理论根基是电磁波的多普勒效应。当目标与雷达之间存在相对径向运动时,接收回波信号的载频将产生一个与径向速度 v 成正比的多普勒频移 f_d 。多普勒谱图的生成通过对一个相干处理间隔内的 N 个脉冲回波序列进行频谱估计来实现。设来自同一距离单元

的慢时间序列为 $s(n), n = 0, 1, \dots, N-1$,其离散傅里叶变换定义了该距离单元的多普勒谱,表达式为

$$S(k) = \sum_{n=0}^{N-1} s(n) \cdot e^{-j2\pi \frac{kn}{N}}, k = 0, 1, \dots, N \quad (2)$$

式中, $S(k)$ 是第 k 个多普勒单元的复频值。

为了直观显示频谱结构,通常执行快速傅里叶变换(Fast Fourier transform, FFT)移位,将零频分量移至频谱中心。多普勒频率分辨率 Δf_d 是衡量速度分辨能力的关键参数,与总相干积累时间成反比,表达式为

$$\Delta f_d = \frac{1}{T_{\text{CPI}}} = \frac{PRF}{N} \quad (3)$$

式中, PRF 为脉冲重复频率。对于一个理想的点状目标在匀速运动时,其多普勒谱表现为一个位于对应处的尖锐主瓣。主瓣的宽度由式(3)决定,而较低的旁瓣电平则反映良好的系统设计与信号处理质量。观测到能量集中、轮廓陡峭的单一谱峰,标志着目标具有稳定的径向速度且散射特性均匀。

2.2 雷达目标跟踪数据特征提取

目标的运动特征通常由位置、速度和加速度在笛卡尔坐标系下表征。然而,雷达的观测值距离 r 、方位角 α 和俯仰角 θ 是在极坐标系下获得的。为求解目标的飞行速度,需将极坐标系下的观测值转换至笛卡尔坐标系。该坐标转换的表达式为

$$\begin{aligned} x_k &= r_k \sin \alpha_k \cos \theta_k \\ y_k &= r_k \cos \alpha_k \cos \theta_k \\ z_k &= r_k \sin \theta_k \end{aligned} \quad (4)$$

式中, x_k, y_k 和 z_k 表示 k 时刻目标分别在笛卡尔坐标系 x, y 和 z 方向的位置分量。

目标飞行速度的表达式为

$$v_k = \sqrt{v_{x,k}^2 + v_{y,k}^2 + v_{z,k}^2} \quad (5)$$

式中, $v_{x,k}, v_{y,k}$ 和 $v_{z,k}$ 表示 k 时刻目标分别在 x, y 和 z 方向的速度分量。具体计算表达式为

$$v_{x,k} = \frac{x_k - x_{k-1}}{t_k - t_{k-1}}, v_{y,k} = \frac{y_k - y_{k-1}}{t_k - t_{k-1}}, v_{z,k} = \frac{z_k - z_{k-1}}{t_k - t_{k-1}} \quad (6)$$

加速度描述目标的速度变化快慢和机动灵活性,计算公式为

$$a_k = \frac{v_k - v_{k-1}}{t_k - t_{k-1}} \quad (7)$$

2.3 雷达目标识别数据特征提取

从窄带高重频数据中提取的目标微动特性,本质上源于其旋转部件引起的多普勒效应。根据目标类别,微动特性可分为飞机等气动飞行器的微动特性,弹道等自旋稳定飞行器的微动特性。

以气动目标为例,微多普勒调制主要由旋转部件的周期性运动引起,如直升机旋翼转动、螺旋桨桨叶转动等。图1给出了桨叶相对雷达的几何关系示意图,根据该几何模型可以建立微多普勒调制的数学模型。




图1 微多普勒几何模型

如图1所示,距离雷达 R_0 处的目标,其旋转部件包含 N 个桨叶,每个桨叶是同类线性刚性天线,且无桨叶遮挡。分别以雷达 O 和桨叶旋转中心 o 为坐标中心建立坐标系。假设飞机相对于雷达视线的径向速度为 v ,飞行方向为远离雷达,桨叶旋转中心(o 点)相对于雷达的方位角和仰角分别为 α 和 β ,桨叶高度为 h ,桨叶旋转角速度为 ω_r , R_0 为旋转中心(o 点)到雷达的初始距离。有效桨叶长度为 $L = L_2 - L_1$, L_1 为桨叶根部离旋转中心的距离(对于直升机的桨叶,桨叶根部与旋转中心重合,即 $L_1 = 0$;对于螺旋桨飞机和涡扇喷气飞机的桨叶, $L_1 \neq 0$), L_2 为桨叶尖部离旋转中心的距离, θ_0 为基准桨叶的旋转初相角, λ 为雷达波长。

设雷达发射的窄带相参信号为 $u(t) =$

$\exp(j2\pi f_0 t)$,其中, f_0 为雷达载频,则其回波信号可以表示为

$$x(t) = a(t)\exp(j2\pi f_0 t + \varphi(t)) = X(t)\exp(j2\pi f_0 t) \quad (8)$$

式中, $a(t)$ 表示幅度调制函数, $\varphi(t)$ 表示相位调制函数, $X(t)$ 表示包含了幅相调制信息的复包络信号。不考虑机身分量和噪声,则可得 N 个桨叶的合成散射回波为

$$S_N(t) = \sum_{k=0}^{N-1} (L_2 - L_1) \exp[-j \frac{4\pi}{\lambda} (R_0 + vt + \frac{L_1 + L_2}{2} \times \cos\beta \cos(\theta_0 + \frac{2\pi k}{N} + \omega_r t - \alpha))] \times \sin c[\frac{2\pi}{\lambda} (L_2 - L_1) \cos\beta \times \cos(\theta_0 + \frac{2\pi k}{N} + \omega_r t - \alpha)] \exp(j2\pi f_0 t) \quad (9)$$

对上述时域回波进行傅立叶变换,得到回波的频域表示为

$$S_N(f) = \sum_{n=-N_1}^{N_1} c_n \delta(f - nf_T) \quad (10)$$

式中, c_n 表示谱线幅度,由参数 $\lambda, N, \beta, \theta_0, L_1, L_2$ 和Bessel函数决定,谱线间隔 nf_T 表示特征峰之间的间隔,可用于提取目标的旋转转速特征。该式表明,调制谱由一系列线谱构成,其在频谱中的具体形态为一系列特征峰。

2.4 雷达有源干扰数据特征提取

从一维时域和二维时频域两个方面来提取雷达有源干扰数据的特征。

1) 一维时域特征提取

为了高效提取原始基带信号的一维特征,引入了脉冲压缩技术。该技术可以在频域或时域实现,这里采用了FFT的方法,以提升计算效率,避免直接进行线性相关处理的高计算复杂度。其原理为:对输入信号做FFT后,乘以匹配滤波器的数字频率响应,再经过快速傅里叶逆变换(Inverse Fast Fourier Transform, IFFT)输出压缩后的信号序列。

假设线性调频视频信号的复包络为

$$s_{in}(n) = A \cdot \exp(j\pi K(nT_s)^2), \quad 0 \leq nT_s \leq \tau, K = B/\tau \quad (11)$$

式中, B 表示信号带宽, τ 表示信号时宽, T_s 为采样周期, n 为采样点。

$$\begin{aligned} & \text{信号 } s_{\text{in}}(n) \text{ 的频谱为} \\ & S_{\text{in}}(\omega) = \text{FFT}(s_{\text{in}}(n)) \end{aligned} \quad (12)$$

匹配滤波器的频率响应表达式为

$$H_{\text{MF}}(\omega) = \text{conj}(S_{\text{in}}(\omega)) \quad (13)$$

式中, $\text{conj}(\cdot)$ 表示取共轭。

脉冲压缩后的输出信号为

$$s_{\text{out}}(n) = \text{IFFT}(H_{\text{MF}}(\omega) \cdot S_{\text{in}}(\omega)) \quad (14)$$

2) 时频域二维特征提取

复杂电磁环境中的干扰信号都是时变信号。对于时变信号, 传统的傅里叶变换无法反映其频率随时间变化的情况, 而时频分析方法则可以把信号描述为时间和频率的二维函数, 基于干扰信号时间和频率的关系来分析信号特征。

使用短时傅里叶变换 (Short-Time Fourier Transform, STFT) 来提取干扰信号的时频域特征。STFT 本质上是加窗的傅里叶变换, 通过窗函数的移动来获取不同时间内的频率分量。STFT 的显著优点是计算较为简单, 可以利用 FFT 来实现, 其计算公式为

$$X_m(f) = \sum_{n=-\infty}^{\infty} x(n) g(n - mR) e^{-j2\pi fn} \quad (15)$$

在 STFT 中, 利用窗口长度为 M 的滑动窗口将信号 $x(n)$ 划分为短时间信号, 每两个相邻窗口之间的重叠长度为 L , 每个窗口滑动距离为 $R = M - L$ 。对每个窗口中的信号采用 FFT 完成离散傅里叶变换 (Discrete Fourier Transform, DFT), 在窗口向后滑动过程中, 获得多个 DFT 结果 $X_m(f)$, 将每个滑窗生成的 DFT 结果按列存储为矩阵 $[X_1(f), X_2(f), \dots, X_k(f)]$, 即可得到二维的 STFT 特征。

2.5 雷达 SAR 图像数据提取

在数据预处理阶段, 首先使用 Mosaic 方法对数据进行增强, 同时对图像进行随机翻转、随机缩放、随机裁剪及亮度调整等操作, 以此增加数据的多样性。然后对图像进行缩放与填充, 将图像尺寸调整为模型输入尺寸, 对不足部分进行填充。

最后进行归一化, 将图像像素值归一化到 (0,1) 区间。均值方差标准化公式为

$$I_{\text{norm}(c,h,w)} = \frac{I_{\text{pad}(c,h,w)}}{255.0} - \frac{\text{mean}[c]}{\text{std}[c]} \quad (16)$$

式中, $I_{\text{pad}(c,h,w)}$ 表示缩放填充后的 $S \times S$ 大小的图像, 像素值仍为 $[0, 255]$, c 表示图像通道索引, $\text{mean}[\cdot]$ 和 $\text{std}[\cdot]$ 分别表示均值和方差, $I_{\text{norm}(c,h,w)}$ 表示归一化后的图像, 其分布更接近标准正态分布。这使得优化曲面更为平滑, 从而有效加快了模型的收敛速度。

模型设计网络结构依次由输入端、Backbone、Neck 及 Head 四部分构成。输入端实现数据预处理过程, 处理后的图像大小为 $S \times S \times 3$, 其中 3 代表 RGB 三个通道。Backbone 将跨层连接 (CSP) 模块和残差块结合的 CSPDarknet53 作为特征提取网络, 引入的 CSP 模块在减少计算量的同时保持特征提取的能力。CSP 模块保留的特征信息为

$$F_{\text{out}} = \text{Concat}(F_{\text{main}}, F_{\text{sub}}) \quad (17)$$

式中, F_{main} 表示主分支的输出, F_{sub} 表示次分支的输出。

Darknet53 是一种轻量化的残差网络, 通过使用较小的卷积核减少计算量。输出表达式为

$$F_{\text{out}} = F_{\text{in}} + \text{Conv}(F_{\text{in}}) \quad (18)$$

式中, $\text{Conv}(\cdot)$ 表示卷积操作。

Neck 是目标检测网络中进行多尺度特征融合的模块。对 Backbone 提取到的特征进行压缩, 通过不同尺度特征融合后的特征张量, 实现多尺度目标检测。基于 Neck 模块获取不同尺度的特征张量, Head 使用回归目标框的坐标和置信度实现目标定位。预测目标框坐标 (中心点坐标和宽高) 的公式为

$$(x, y, w, h) = \text{Conv}_3(F) \quad (19)$$

式中, F 表示融合后的特征图, $\text{Conv}_3(\cdot)$ 表示卷积操作。

预测目标类别概率的公式为

$$P_c = \text{Softmax}(\text{Conv}_4(F)) \quad (20)$$

式中, P_c 表示目标类别概率。

预测目标框置信度 (目标存在的概率) 的公式为

$$P_o = \sigma(\text{Conv}_5(F)) \quad (21)$$

式中, $\sigma(\cdot)$ 表示 sigmoid 函数。

通过非最大值抑制(NMS)对候选框进行筛选, 去除与其 IoU (交并比) 较高的其他候选框。IoU 的计算公式为

$$\text{IoU} = \frac{\text{Area}(B_1 \cap B_2)}{\text{Area}(B_1 \cup B_2)} \quad (22)$$

式中, B_1 和 B_2 分别表示两个候选框。

SAR 图像目标检测损失函数由回归损失函数、目标置信度损失函数及分类损失函数3部分组成。回归损失函数在于量化真实框与预测框之间的差异, 目标置信度损失函数表征框的目标性, 分类损失函数表征真实类别与预测类别之间的差异程度。损失函数的数学表达式为

$$\text{Loss} = \lambda_{\text{box}} L_{\text{box}} + \lambda_{\text{obj}} L_{\text{obj}} + \lambda_{\text{cls}} L_{\text{cls}} \quad (23)$$

式中, L_{box} 、 L_{obj} 和 L_{cls} 分别表示回归损失函数、置信度损失函数和分类损失函数, λ_{box} 、 λ_{obj} 和 λ_{cls} 表示相应的权重系数。

3 数据集特性分析

3.1 雷达目标检测数据特征分析

以雷达目标检测数据集中的 dataEcho5145 (位置标签为 402) 样本为代表, 分析其在空间域和频率域特征的分布情况。图 2 给出了空间域距离单元-幅度分布, 图中距离单元-幅度曲线在距离单元 402 处出现显著尖峰, 与数据集位置标签完全吻合, 验证了数据标注的准确性。该特征表明这个距离单元存在强散射目标。




图2 距离单元-幅度

图 3 显出了频率域多普勒谱图。从图中可以

看出, 主体回波能量集中, 在零频附近呈现显著尖峰, 信噪比优良。该谱型反映了理想点目标的回波特性。




图3 多普勒谱图

3.2 雷达目标跟踪数据特征分析

根据航迹数据中记录的与之关联的点迹序列号, 数据处理以此序列号列表为索引, 通过查询点迹数据集来获取该航迹所对应的全部点迹详细信息。以航迹数据中的 R_109.csv 数据为代表, 分析跟踪数据下的目标运动特征。图 4 给出了目标的距离-时间分布。从图中可以看出, 目标距离随时间变化均匀, 且呈现先接近后远离的趋势。




图4 目标时间-距离分布

图 5 和图 6 分别给出了目标时间-速度分布和目标时间-加速度分布。如图所示, 民航目标的速度大小分布在区间 $[150 \text{ m/s}, 250 \text{ m/s}]$, 且加速度变化较小; 当民航目标进入平稳飞行时, 速度大小几乎不变, 加速度约为零。




图5 目标时间-速度分布




图6 目标时间-加速度分布


3.3 雷达目标识别数据特征分析

飞机目标相对于雷达运动产生了两种多普勒效应,第一种是飞机自身运动产生的主多普勒效应,第二种是发动机转子旋转产生的微多普勒效应。微多普勒一般较弱,比主多普勒弱十几到几十分贝。从窄带高重频数据中可以获得飞机目标的微动特性,以雷达目标识别数据库中的A319-115数据文件中的一条数据为代表,对窄带高重频数据下的目标微动特性进行分析。


图7给出了窄带高重频数据在时域和频域的分布。由于微动特性在频谱上表现为多个不同频点的线谱,因此从频谱角度分析目标微动特性更为直观。从图7(b)可以看出,主多普勒峰对应的频率约为-1 600 Hz,表征了飞机相对于雷达的径向速度,且微多普勒峰有多个,显示了目标的微动特性。

图8给出了基于短时傅里叶变换的时频图。如图8所示,飞机运动在-1 600 Hz附近的深红色色带,在-950 Hz, 750 Hz, 1 800 Hz附近的淡黄色条带为微动多普勒。值得注意的是,在约50 Hz处出现了一条频谱幅度较高的深红色色带,该条色带

也是微动,呈现深红色的主要原因是,雷达数据中包含了能量较高的低频信息,经过傅里叶变换后,低频附近数据的频谱幅度变高,因此其整体幅度值较强于其他三条微动色带。



(a) 时间-幅度



(b) 频率-幅度

图7 窄带高重频数据的时域和频域分布




图8 时频图

将主多普勒移至零频处,对飞机目标的径向速度进行补偿。如图9所示,当频谱以主多普勒为零频时,微多普勒以主多普勒为中心左右对称,谱线间隔约为1 000 Hz。

民航飞机进入巡航阶段后,飞行状态趋于稳定,因此谱线间隔可作为区分不同民航机型的有效判别依据。图10给出了识别数据集中2型民航的典型频谱图。从图中可以看出,不同类型民航飞机的微多普勒数值不相同。






图9 径向速度补偿后频谱



(a) 型号 A320-214



(b) 型号 A320-232

图10 目标识别数据集中2型民航频谱


3.4 雷达有源干扰数据特征分析

每条数据样本包含1~3种干扰类型。当某一数据样本仅含有一种干扰类型时,该条数据样本为单干扰数据,当干扰类型多于一种时,为复合干扰。以阻塞式噪声干扰作为单干扰的代表,以噪声乘积干扰、间歇采样转发干扰与阻塞式噪声干扰三者构成的多干扰作为复合干扰的代表,分别对单干扰与复合干扰下的数据特征进行分析。


3.4.1 单干扰数据特征分析

图11给出了阻塞式噪声干扰的时域和时频域分析结果。其中,时频图中的黑色方框标记了干扰信号出现的时间段,脉压信号时域图中的红圈标记了目标所在位置。从图中可以看出,当干扰


信号能量较强时,在脉冲压缩前,干扰信号在时域和时频域均对目标信号进行全遮盖。在脉冲压缩后,部分目标信号仍被淹没在干扰信号中。




(a) 原始信号时域



(b) 原始信号时频域



(c) 脉压信号时域




(d) 脉压信号时频域


图11 阻塞式噪声干扰

3.4.2 复合干扰数据特征分析


图12给出了包含噪声乘积干扰、间歇采样转发干扰及阻塞式噪声干扰3种干扰样式的复合干扰在时域和时频域的特征分布。时频图中的黑色方框、红色方框以及蓝色方框分别为这三种干扰的作用范围。从脉压信号时域图中可以看出,近距离单元处的噪声乘积干扰脉压后形成多个尖峰,中间距离单元的间歇采样转发干扰脉压后形成多个假目标,二者对雷达检测造成欺骗,远距离单元的阻塞式噪声干扰对第三个目标信号形成压制遮盖。




(a) 原始信号时域



(b) 原始信号时频域



(c) 脉压信号时域



(d) 脉压信号时频域

图12 包含噪声乘积干扰、间歇采样转发干扰及阻塞式噪声干扰3种干扰样式的复合干扰

3.5 雷达SAR图像数据集结果分析

基于发布的SAR图像数据集,使用深度学习方法对SAR图像数据进行目标检测,数据集涵盖舰船、飞机、桥梁及油罐4类目标。将样本平衡后的数据按8:2的比例划分为训练集和测试集。模型训练时,Epoch设置为200,初始学习率设置为0.01。然后对训练模型进行测试,置信度阈值设置为0.5,IoU阈值设置为0.5。测试结果如表10所示。

表10 目标检测结果

目标	查全率	查准率
舰船	0.858	0.864
飞机	0.876	0.653
油罐	0.872	0.893
桥梁	0.905	0.931
总计	0.878	0.835


图13分别显示了舰船和桥梁2类目标的检测结果。从图中可以看出,基于发布数据集训练的神经网络模型可以有效检测出图像中的舰船和桥梁目标。

4 结束语

针对现有公开数据集因模拟环境失真与功能单一,难以满足复杂电磁环境下全链路技术研究的问题,本文公开了一套完整的雷达检测跟踪识别一体化数据集。该数据集源于典型的实测场景,涵盖了信号处理、目标跟踪、精细识别、复合干扰以及高分辨率SAR图像的多波段、多模态数据,



(a) 舰船



(b) 桥梁

图13 舰船与桥梁的SAR图像

真实反映复杂环境下雷达信号的传播特性与目标特性。此数据集填补了多任务雷达探测感知数据集的空白,将为该领域的协同创新与性能突破奠定基石。项目团队致力于此数据集的长期迭代与完善,并期待研究社区的反馈能共同推动其发展。BWRadarDataset-1.0:多波段多模态雷达探测感知数据集依托《雷达科学与技术》官方网站发布,数据及说明已同步上传,网址为:<http://radarst.ijournal.cn>。

参考文献:

- [1] 吴浩,李刚,崔雄文.一种基于距离-多普勒图的雷达目标智能检测识别算法[J].雷达科学与技术,2025,23(3):237-242.
- [2] 汪翔,王彦斌,汪育苗,等.基于图神经网络的多尺度特征融合雷达目标检测方法[J].雷达科学与技术,2025,23(1):39-47.
- [3] 张良,徐艳国,孙晓闻,等.空基智能预警探测体系架构及关键技术[J].现代雷达,2024,46(12):1-7.
- [4] 叶宇,叶星炜,欧阳可赛,等.后羿基础模型:“预训练-微调”范式下的雷达数据智能处理方法[J].现代雷达,2025,47(8):1-9.
- [5] 陈佳音,郭山红,朱海锐,等.基于多特征融合的海面目标智能检测算法[J].现代雷达,2024,46(12):24-30.
- [6] 宋志勇,回丙伟,范红旗,等.雷达回波序列中弱小飞机目标检测跟踪数据集[J].中国科学数据(中英文网络版),2020,5(3):277-290.
- [7] 关键,刘宁波,王国庆,等.雷达对海探测试验与目标特性数据获取——海上目标双极化多海况散射特性数据集[J].雷达学报,2023,12(2):456-469.
- [8] 陈小龙,袁旺,杜晓林,等.多波段FMCW雷达低慢小探测数据集(LSS-FMCWR-1.0)及高分辨微动特征提取方法[J].雷达学报,2024,13(3):539-553.
- [9] 陈小龙,饶桂林,关键,等.被动雷达低慢小探测数据集(LSS-PR-1.0)及多域特征提取和分析方法[J].雷达学报(中英文),2025,14(2):249-268.
- [10] 林钱强,秦正阳,蒋李兵,等.简单野外背景条件下地面雷达对“低慢小”无人机探测数据集[J].信号处理,2024,40(11):2095-2104.
- [11] 刘宁波,李佳,王国庆,等.雷达对海探测试验与目标特性数据获取——海上目标多源观测数据集[J].雷达学报(中英文),2025,14(3):754-780.
- [12] 程永强,邹润明,陈嘉宜,等.地杂波背景下雷达低慢小无人机探测数据集(LSS-Ku-1.0)[J].信号处理,2025,41(5):807-820.
- [13] 回丙伟,宋志勇,范红旗,等.地/空背景下红外图像弱小飞机目标检测跟踪数据集[J].中国科学数据(中英文网络版),2020,5(3):291-302.
- [14] 伍琼燕,赵征鹏,王林飞,等.复杂道路监控场景下的车辆检测与跟踪数据集[J].应用科技,2024,51(1):10-18.
- [15] 刘丽华,陈志豪,杨皓宇,等.面向对海监视的舰船目标跟踪与航迹融合数据集[J].中国科学数据(中英文网络版),2024,9(01):260-272.
- [16] 肖云,曹丹,李成龙,等.基于高空无人机平台的多模态跟踪数据集[J].中国图象图形学报,2025,30(2):361-374.
- [17] SUN Xian, WANG Peijin, YAN Zhiyuan, et al. FAIR1M: A Benchmark Dataset for Fine-Grained Object Recognition in High-Resolution Remote Sensing Imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 184:116-130.

- [18] HAROON M, SHAHZAD M, FRAZ M M. Multisized Object Detection Using Spaceborne Optical Imagery [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13:3032-3046.
- [19] 禹文奇, 程堃, 王美君, 等. MAR20: 遥感图像军用飞机目标识别数据集[J]. 遥感学报, 2023, 27(12): 2688-2696.
- [20] 任俊宇, 俞宁宁, 周成伟, 等. DroneRFb-DIR: 用于非合作无人机个体识别的射频信号数据集[J]. 电子与信息学报, 2025, 47(3):573-581.
- [21] 刘国满, 聂旭娜. 一种基于卷积神经网络的雷达干扰识别算法[J]. 北京理工大学学报, 2021, 41(9): 990-998.
- [22] 郭立民, 黄文青, 陈前, 等. 轻量化的ML-SNet雷达复合干扰识别算法[J]. 系统工程与电子技术, 2025, 47(2):418-427.
- [23] 李佳浩, 杜子铭, 周博, 等. 基于对抗互易点学习的无人机通信干扰开集识别方法[J]. 信号处理, 2024, 40(4):639-649.
- [24] 郭文杰, 吴振华, 曹宜策, 等. 多域浅层特征引导下雷达有源干扰多模态对比识别方法[J]. 雷达学报, 2024, 13(5):1004-1018.
- [25] 陈思伟, 崔兴超, 李铭典, 等. 基于深度CNN模型的SAR图像有源干扰类型识别方法[J]. 雷达学报, 2022, 11(5):897-908.
- [26] 王佳祥, 孟进, 李伟, 等. YOLO-S3: 一种轻量化的雷达复合干扰识别网络[PP/OL]. 雷达学报(中英文). (2025-08-18) [2025-11-15]. <https://link.cnki.net/urlid/10.1030.TN.20250818.1048.002>.
- [27] 李健伟, 曲长文, 邵嘉琦, 等. 基于深度学习的SAR图像舰船检测数据集及性能分析[C]//第五届高分辨率对地观测学术年会论文集, 中国西安: 高分辨率对地观测学术联盟, 2018:180-201.
- [28] 徐从安, 苏航, 李健伟, 等. RSDD-SAR: SAR舰船斜框检测数据集[J]. 雷达学报, 2022, 11(4):581-599.
- [29] 仇晓兰, 焦泽坤, 彭凌霄, 等. SAR-MV3D-1.0: SAR微波视觉三维成像数据集[J]. 雷达学报, 2021, 10(4): 485-498.
- [30] 仇晓兰, 焦泽坤, 杨振礼, 等. 微波视觉三维SAR关键技术及实验系统初步进展[J]. 雷达学报, 2022, 11(1): 1-19.
- [31] CHEN Zhanye, TANG Shiyang, REN Yi, et al. Curvilinear Flight Synthetic Aperture Radar (CF-SAR): Principles Methods, Applications, Challenges and Trends [J]. Remote Sensing, 2022, 14(13): 2983.
- [32] VASILE G, CONGEDO M. Comparative Analysis of ICA Based Incoherent Target Decompositions for PolSAR Data [C]//2022 IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia: IEEE, 2022:4415-4418.
- [33] SUN Xiaofan, WANG Bingnan, XIANG Maosheng, et al. Machine Learning Inversion of Forest Vertical Structure Based on 2-D-SGVBVoG Model for P-Band Pol-InSAR [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60:5225115.
- [34] 焦润之, 邓嘉, 韩亚权, 等. 3DSARBuSim 1.0: 人造建筑高分辨率SAR三维成像仿真数据集[J]. 电子与信息学报, 2024, 46(7):2681-2693.
- [35] 金燕, 仇晓兰, 潘洁, 等. MPOLARS-1.0: 多维度SAR多波段全极化精细分类数据集[J]. 雷达学报, 2024, 13(3):525-538.
- [36] 郑乃榕, 杨子安, 施贤正, 等. 机载多维度SAR图像地物数据集构建及融合分类方法[J]. 遥感学报, 2024, 28(9):2209-2222.
- [37] 王汝意, 张汉卿, 韩冰, 等. 基于角度内插仿真的飞机目标多角度SAR数据集构建方法研究[J]. 雷达学报, 2022, 11(4):637-651.
- [38] 雷禹, 冷祥光, 孙忠镇, 等. 宽幅SAR海上大型运动舰船目标数据集构建及识别性能分析[J]. 雷达学报, 2022, 11(3):347-362.
- [39] 王智睿, 赵良瑾, 汪越雷, 等. AIR-PolSAR-Seg-2.0: 大规模复杂场景极化SAR地物分类数据集[J]. 雷达学报(中英文), 2025, 14(2):353-365.

作者简介:

张转花 女, 博士, 工程师, 主要研究方向为雷达数据处理、智能信息处理。

靳俊峰(通信作者) 男, 博士, 研究员, 主要研究方向为雷达数据处理、智能信息处理。

常沛 男, 硕士, 高级工程师, 主要研究方向为遥感图像智能解译。

何洋洋 男, 硕士, 工程师, 主要研究方向为雷达数据处理。

汪振亚 男, 硕士, 工程师, 主要研究方向为空中目标识别。

侯其立 男, 博士, 高级工程师, 主要研究方向为雷达信号处理。

李玉景 女, 硕士, 高级工程师, 主要研究方向为SAR图像检测识别。

DOI:10.3969/j.issn.1672-2337.2026.01.002

基于去相关无偏转换量测的外辐射源雷达跟踪算法

陈书恒, 朱倪瑶, 王海鹏, 张 鑫

(中国人民解放军92728部队, 上海 200436)

摘要: 外辐射源雷达通过接收民用辐射源信号来探测目标, 具有隐蔽性强、成本低廉的优点, 在信息化战争中作用显著。但是辐射源的非合作特性, 导致其观测误差较大, 需采取滤波技术提高估计精度。转换量测卡尔曼滤波(Converted Measurement Kalman Filter, CMKF)是有源雷达中常用的滤波跟踪方法。外辐射源雷达的转换量测模型结构复杂, 非线性强, 给应用CMKF带来困难。通过改进初始化、状态预测、转换量测构建等诸多环节, 设计出用于外辐射源雷达的去相关无偏CMKF。在构建转换量测模型时, 使用了更高精度的等效距离和等效方位来表征目标位置, 因此在低信噪比环境下的滤波精度、置信度优于确定性采样算法, 表现出很强的竞争力。

关键词: 外辐射源雷达; 目标跟踪; 非线性滤波; 去相关无偏转换量测

中图分类号: TN953; TN958.97

文献标志码: A

文章编号: 1672-2337(2026)01-0015-07

引用格式: 陈书恒, 朱倪瑶, 王海鹏, 等. 基于去相关无偏转换量测的外辐射源雷达跟踪算法[J]. 雷达科学与技术, 2026, 24(1): 15-21.

CHEN Shuheng, ZHU Niyao, WANG Haipeng, et al. External Radiation Source Passive Radar Tracking Algorithm Based on Decorrelated Unbiased Converted Measurement [J]. Radar Science and Technology, 2026, 24(1): 15-21.

External Radiation Source Passive Radar Tracking Algorithm Based on Decorrelated Unbiased Converted Measurement

CHEN Shuheng, ZHU Niyao, WANG Haipeng, ZHANG Xin

(Unit 92728 of PLA, Shanghai 200436, China)

Abstract: External radiation source passive radar, which detects targets by receiving signals from civilian transmitters, is valued for its strong stealth capabilities and low cost, playing a significant role in information warfare. Owing to the none-cooperative nature of the radiation source, the measurement errors are relatively large, necessitating the use of filtering technique to improve estimation accuracy. The converted measurement Kalman filter (CMKF) is a commonly used filtering technique for active radar. However, its application in passive radar is challenging due to the complex structure and high nonlinearity of converted measurement model. By improving multiple aspects such as state initialization, state prediction and measurement conversion, a locally consistent unbiased converted measurement Kalman filter is designed for external radiation source passive radar. The filter employs higher-precision equivalent range and equivalent azimuth to characterize the target position during the converted measurement process. As a result, it demonstrates superior accuracy and consistency under low signal-to-noise ratio (SNR) condition compared to canonical deterministic sampling algorithms, which indicates strong competitiveness of the proposed method.

Key words: external radiation source passive radar; target tracking; nonlinear filtering; decorrelated unbiased converted measurement

0 引言

外辐射源雷达^[1-3]自身不辐射电磁波, 而是将第三方(广播电台、电视、基站等)辐射的电磁信号

作为照射源, 通过接收目标对这些信号的反射信号来探测跟踪目标。具有很好的隐蔽性和抗干扰能力, 且成本低廉, 在军事应用上越来越受到重视。外辐射源雷达工作时, 接收站同时接收辐射

源的直达信号和经目标反射的信号,采用信号处理技术,提取方位和时差信息后,估计目标位置并进行跟踪。

雷达跟踪目标时,通常在直角坐标系下建模目标运动,而雷达观测是在极/球坐标系下获取,需要解决用非线性观测跟踪目标的问题。相关研究如扩展卡尔曼滤波^[4](Extended Kalman Filter, EKF)、无迹滤波^[5](Unscented Kalman Filter, UKF)、容积卡尔曼滤波^[6](Cubature Kalman Filter, CKF)、粒子滤波^[7](Particle Filter, PF)、转换量测卡尔曼滤波^[8](Converted Measurement Kalman Filter, CMKF)等方法。CMKF因为精度较高、实时性好、实现容易,在实际应用中较为广泛。CMKF核心思想是将极坐标数据转换为直角坐标系的目标位置表达,再用标准卡尔曼滤波器跟踪。当前对CMKF的研究聚焦如何更精确地表达转换量测统计特性,提高无偏性、一致性和鲁棒性。针对上述研究目标,去偏CMKF^[9-10]、无偏CMKF、修正无偏CMKF、最佳线性无偏估计滤波(BLUE)^[11]、去相关无偏CMKF^[12-13]等方法被相继提出,进一步丰富了CMKF的内涵和应用。

去相关无偏转换量测^[8](Decorrelated Unbiased Converted Measurement, DUCM)是新近出现的CMKF方法,它在构造出转换量测模型后,基于预测值估计转换量测统计特性,较好地解决了困扰转换量测的估计偏差和转换偏差两个问题,体现出一定的优越性。外辐射源雷达中,目标到接收站的距离无法直接测定,因此无法构造目标位置的伪线性表达,导致无法应用DUCM滤波器。为此,提出基于外辐射源雷达的滤波初始化模型,并基于位置预测构造出更高精度的等效距离观测和等效方位观测,用于去相关转换量测模型,收到很好效果。

1 外辐射源雷达定位原理分析

图1是外辐射源雷达对目标的观测模型。接收站Rx位于坐标原点,发射站Tx坐标为 $[L \ 0]^T$,目标T的位置 $[x \ y]^T$,接收站测定的是反射波和直达波的到达时差,以及目标相对接收站的方位。由于发射站和接收站间距已知,因此本质上是测

定发射站所辐射信号,经目标反射后到达接收站的双基距离和。假设时刻 k 的双基距离和用 $r_{m,k}$ 表示,方位观测用 $\alpha_{m,k}$ 表示,极坐标系内的观测向量用 z_k 表示, z_k 和目标T位置 $[x \ y]^T$ 的关系为

$$z_k = \begin{bmatrix} r_{m,k} \\ \alpha_{m,k} \end{bmatrix} = \begin{bmatrix} \sqrt{x^2 + y^2} + \sqrt{(x-L)^2 + y^2} + \tilde{r} \\ \text{tg}^{-1}(y/x) + \tilde{\alpha} \end{bmatrix} \quad (1)$$

双基距离和观测误差 $\tilde{r}$ 满足高斯分布 $\tilde{r} \in N(0, \sigma_r^2)$;方位观测误差 $\tilde{\alpha}$ 满足高斯分布 $\tilde{\alpha} \in N(0, \sigma_\alpha^2)$ 。




图1 外辐射源雷达对目标观测模型

由式(1)可见,目标直角坐标系内位置可以用 $r_{m,k}$ 和 $\alpha_{m,k}$ 表达:

$$\begin{cases} x_{m,k} = \frac{1}{2} \frac{(L^2 - r_{m,k}^2) \cos(\alpha_{m,k})}{L \cos(\alpha_{m,k}) - r_{m,k}} \\ y_{m,k} = \frac{1}{2} \frac{(L^2 - r_{m,k}^2) \sin(\alpha_{m,k})}{L \cos(\alpha_{m,k}) - r_{m,k}} \end{cases} \quad (2)$$

式(2)的转换量测虽然能够表达目标位置,但是模型过于复杂,非线性较强,如果应用到DUCM滤波器中,需要泰勒展开到至少二阶,否则无法估计出转换量测偏差,导致滤波发散。但是二阶泰勒展开的计算代价较大,会产生表达式复杂、计算负荷大的问题。本文提出用于外辐射源雷达的去相关无偏转换量测滤波器,通过滤波器初始化、状态预测和更新步骤的有机结合,以更为简洁的形式表征转换量测,实现一种高精度、高置信度、低复杂度的DUCM滤波器。

2 DUCM滤波算法改进

2.1 滤波初始化

在初始化阶段,收集时刻0和1的连续两帧观测,用两点起始法,估计目标初始状态。

假设目标状态估计为 $\hat{x}_k = [\hat{x}_k \ \hat{y}_k \ \hat{\dot{x}}_k \ \hat{\dot{y}}_k]^T$

($k = 0, 1, 2, \dots$)。 $\hat{x}_k, \hat{y}_k$ 是时刻 k 的位置估计在各轴的投影; $\hat{\dot{x}}_k, \hat{\dot{y}}_k$ 是时刻 k 的速度估计在各轴的投影。雷达连续两帧的观测为 $r_{m,k}$ ($k = 0, 1$), $\alpha_{m,k}$ ($k = 0, 1$), 由式(2)可知, 时刻 k 的目标状态估计可表示为

$$\begin{cases} \hat{x}_k = \frac{1}{2} \frac{(L^2 - r_{m,k}^2) \cos(\alpha_{m,k})}{L \cos(\alpha_{m,k}) - r_{m,k}} \\ \hat{y}_k = \frac{1}{2} \frac{(L^2 - r_{m,k}^2) \sin(\alpha_{m,k})}{L \cos(\alpha_{m,k}) - r_{m,k}} \\ \hat{\dot{x}}_k = (\hat{x}_k - \hat{x}_{k-1})/T \\ \hat{\dot{y}}_k = (\hat{y}_k - \hat{y}_{k-1})/T \end{cases} \quad (3)$$

式中, T 是前后两帧的时间间隔。

式(3)的 $\hat{x}_k, \hat{y}_k$ 对 $r_{m,k}, \alpha_{m,k}$ 分别求微分, 可以建立线性关系:

$$\begin{bmatrix} \tilde{x}_k \\ \tilde{y}_k \end{bmatrix} = \mathbf{A} \begin{bmatrix} \tilde{r} \\ \tilde{\alpha} \end{bmatrix} \quad (4)$$

式中, $\tilde{x}_k, \tilde{y}_k$ 是时刻 k 的位置估计误差在各轴的投影。矩阵 $\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$, 其各元素表达式为

$$\begin{aligned} a_{11} &= \frac{[L^2 - 2r_{m,1}L \cos(\alpha_{m,1}) + r_{m,1}^2] \cos(\alpha_{m,1})}{2r_{m,1} - 2L \cos^2(\alpha_{m,1})} \\ a_{12} &= \frac{r_{m,1}(L^2 - r_{m,1}^2) \sin(\alpha_{m,1})}{2r_{m,1} - 2L \cos^2(\alpha_{m,1})} \\ a_{21} &= \frac{[L^2 - 2r_{m,1}L \cos(\alpha_{m,1}) + r_{m,1}^2] \sin(\alpha_{m,1})}{2r_{m,1} - 2L \cos^2(\alpha_{m,1})} \\ a_{22} &= \frac{[L - r_{m,1} \cos(\alpha_{m,1})](L^2 - r_{m,1}^2)}{2r_{m,1} - 2L \cos^2(\alpha_{m,1})} \end{aligned} \quad (5)$$

基于双基距离和误差 σ_r 和方位误差 σ_α , 得到时刻 1 的观测协方差阵 $\mathbf{R}_1$:

$$\mathbf{R}_1 = \mathbf{A} \begin{bmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_\alpha^2 \end{bmatrix} \mathbf{A}^T \quad (6)$$

基于式(6), 估计时刻 1 的状态协方差阵 $\hat{\mathbf{P}}_1$:

$$\hat{\mathbf{P}}_1 = \begin{bmatrix} \mathbf{R}_1 & \frac{\mathbf{R}_1}{T} \\ \frac{\mathbf{R}_1}{T} & \frac{2\mathbf{R}_1}{T^2} \end{bmatrix} \quad (7)$$

2.2 状态预测

从时刻 2 开始, 收到新的观测后, 预测目标

状态。

$$\begin{cases} \bar{\mathbf{x}}_k = \mathbf{F}_{k/k-1} \hat{\mathbf{x}}_{k-1} \\ \bar{\mathbf{P}}_k = \mathbf{F}_{k/k-1} \hat{\mathbf{P}}_{k-1} \mathbf{F}_{k/k-1}^T + \mathbf{Q}_k \end{cases} \quad (8)$$

式中, $\mathbf{F}_{k/k-1}$ 是状态转移矩阵。 $\hat{\mathbf{x}}_{k-1}$ 是 $k-1$ 时刻状态估计, $\bar{\mathbf{x}}_k = [\bar{x}_k \ \bar{y}_k \ \bar{\dot{x}}_k \ \bar{\dot{y}}_k]^T$ 是 k 时刻状态预测。 $\bar{x}_k, \bar{y}_k$ 是 k 时刻的位置估计在各轴的投影; $\bar{\dot{x}}_k, \bar{\dot{y}}_k$ 是 k 时刻速度估计在各轴的投影。 $\hat{\mathbf{P}}_{k-1}$ 是 $k-1$ 时刻状态估计协方差阵, $\bar{\mathbf{P}}_k$ 是 k 时刻状态预测协方差阵。 $\mathbf{Q}_k$ 是 k 时刻状态噪声协方差阵。

除了式(8)的预测公式, 还需要计算目标到接收站的距离预测 $\bar{r}_R$, 目标到发射站的距离预测 $\bar{r}_T$, 以及目标到接收站的方位预测 $\bar{\alpha}_R$, 为 2.3 节构建转换量测模型做准备。

$$\bar{r}_R = \sqrt{\bar{x}_k^2 + \bar{y}_k^2} \quad (9)$$

$$\bar{r}_T = \sqrt{(\bar{x}_k - L)^2 + \bar{y}_k^2} \quad (10)$$

$$\bar{\alpha}_R = \tan^{-1} \frac{\bar{y}_k}{\bar{x}_k} \quad (11)$$

距离预测 $\bar{r}_R$ 的方差为

$$\sigma_{r_R}^2 = \text{cov}(\bar{r}_R) = \frac{1}{\bar{r}_R^2} [\bar{x}_k \ \bar{y}_k] \bar{\mathbf{P}}_k^p [\bar{x}_k \ \bar{y}_k]^T \quad (12)$$

式中, $\bar{\mathbf{P}}_k^p$ 是 $\bar{\mathbf{P}}_k$ 的位置分量所组成的协方差阵。

方位预测 $\bar{\alpha}_R$ 的方差为

$$\sigma_{\alpha_R}^2 = \text{cov}(\bar{\alpha}_R) = \frac{1}{\bar{r}_R^4} [-\bar{y}_k \ \bar{x}_k] \bar{\mathbf{P}}_k^p [-\bar{y}_k \ \bar{x}_k]^T \quad (13)$$

式(9)~(13)将在下一节的转换量测构造时发挥作用。

2.3 转换量测构造

为降低转换量测的非线性, 构造以下的转换量测模型。

$$\mathbf{z}_k^{\text{DUCM}} = e^{\sigma_e^2/2} r_e \begin{bmatrix} \cos \alpha_e \\ \sin \alpha_e \end{bmatrix} \quad (14)$$

式(14)的表达式和有源雷达的转换量测模型相似, 但远比式(2)简洁, 能有效降低计算复杂度和非线性。下面对相关参数详细解释。

式(14)中, r_e 是等效距离, 表达式为

$$r_e = \kappa_1 r_{m,k} \quad (15)$$

式中, κ_1 是双基距离和系数,

$$\kappa_1 = \frac{\bar{r}_R}{\bar{r}_R + \bar{r}_T} \quad (16)$$

$\bar{r}_R$ 和 $\bar{r}_T$ 已在式(9)和式(10)中定义。由式(16)可见,当 $\bar{r}_R$ 远大于其预测误差 $\tilde{r}_R$, $\bar{r}_T$ 远大于其预测误差 $\tilde{r}_T$ 时,有 $\kappa_1 \approx \frac{r_R + \tilde{r}_R}{r_R + r_T} \approx \frac{r_R}{r_R + r_T}$, 即 κ_1 取值和预测误差无关。特别地,当发射站和接收站位置相同时, $\kappa_1 = 0.5$, 此时式(14)和有源雷达的转换量测模型是等价的。

κ_1 取值小于1, 因此

$$\sigma_{r_e}^2 = \text{cov}(r_e) = \kappa_1^2 \sigma_r^2 < \sigma_r^2 \quad (17)$$

等效距离精度优于双基距离和精度。

式(14)中的 α_e 是等效方位,

$$\alpha_e = \kappa_2 \alpha_{m,k} + (1 - \kappa_2) \bar{\alpha}_R \quad (18)$$

式中, κ_2 的取值介于0和1之间, 是方位加权系数。等效方位的方差为

$$\sigma_{\alpha_e}^2 = \text{cov}(\alpha_e) = \kappa_2^2 \sigma_\alpha^2 + (1 - \kappa_2)^2 \sigma_{\bar{\alpha}_R}^2 \approx \kappa_2^2 \sigma_\alpha^2 \quad (19)$$

由式(15)和式(18)可见, r_e 、 α_e 都是零均值高斯分布, 此时式(14)和文献[2]的公式(4)完全一致, 是无偏转换量测。

为了使 $\sigma_{\alpha_e}^2$ 表达式简洁, 式(19)做了近似, 下面将证明在一定条件下, 式(19)是合理的。

κ_2 取值需要同时满足式(20)的两个不等式。 ρ 是比例系数, 其取值大于50。

$$\begin{cases} \kappa_2^2 \sigma_\alpha^2 > \rho \sigma_{\alpha_R}^2 \\ \sigma_r^2 + 0.5 \kappa_2^4 \sigma_\alpha^4 \bar{r}_R^2 > \rho \sigma_{r_R}^2 \end{cases} \quad (20)$$

式(20)分别在切向和径向对 κ_2 取值进行约束。不等式1是切向约束, 含义是等效方位误差均方远大于方位预测误差均方。可见当 $\rho > 50$ 且不等式1成立时, 式(19)的近似是合理的。不等式2是径向约束, σ_r^2 是测距误差均方, $0.5 \kappa_2^4 \sigma_\alpha^4 \bar{r}_R^2$ 是测角误差在视轴投影的误差均方, 两种误差均方之和远大于预测距离误差均方。

由式(20)可得 κ_2 表达式:

$$\kappa_2 = \max \left\{ \frac{1}{\sigma_\alpha} \sqrt{\frac{\rho \sigma_{r_R}^2 - \sigma_r^2}{0.5 \bar{r}_R^2}}, \frac{\sigma_{\alpha_R}}{\sigma_\alpha} \sqrt{\rho} \right\} \quad (21)$$

综上所述, 式(14)不但表达简洁, 且等效距离精度优于双基距离和, 等效方位精度优于方位观测。

2.4 状态更新

状态更新阶段的核心步骤是估计转换量测的协方差阵 R_k 。

假设 $R_k = \begin{bmatrix} r_{11} & r_{12} \\ r_{21} & r_{22} \end{bmatrix}$, 则有

$$r_{11} = E \left\{ \left[r \cos(a) - e^{\sigma_{\alpha_e}^2/2} r_e \cos(\alpha_e) \right]^2 \right\} \quad (22)$$

预测距离 $\bar{r}_R$, 等效距离 r_e 与真值 r 的关系为

$$\begin{cases} \bar{r}_R = r + \tilde{r}_R \\ r_e = r + \kappa_1 \tilde{r} \end{cases} \quad (23)$$

方位预测与真值关系为

$$\begin{cases} \bar{\alpha}_R = \alpha + \tilde{\alpha}_R \\ \alpha_m = \alpha + \kappa_2 \tilde{\alpha} \end{cases} \quad (24)$$

因此 r_{11} 有如下形式

$$r_{11} = E \left\{ \left[(\bar{r}_R - \tilde{r}_R) \cos(\bar{\alpha}_R - \tilde{\alpha}_R) - e^{\sigma_{\alpha_e}^2/2} (\bar{r}_R - \tilde{r}_R + \kappa_1 \tilde{r}) \cos(\bar{\alpha}_R - \tilde{\alpha}_R + \kappa_2 \tilde{\alpha}) \right]^2 \right\} \quad (25)$$

经过化简, 最终得到

$$r_{11} = \frac{1}{2} (\bar{r}_R^2 + \kappa_1^2 \sigma_r^2 + \sigma_{r_R}^2) \left[1 + \cos(2\alpha_R) e^{-2\kappa_1^2 \sigma_\alpha^2} e^{-2\sigma_{\alpha_R}^2} \right] \cdot e^{\kappa_1^2 \sigma_\alpha^2} - \frac{1}{2} (\bar{r}_R^2 + \sigma_{r_R}^2) \left[1 + \cos(2\alpha_R) e^{-2\sigma_{\alpha_R}^2} \right] \quad (26)$$

类似可推导出其他元素

$$r_{22} = \frac{1}{2} (\bar{r}_R^2 + \kappa_1^2 \sigma_r^2 + \sigma_{r_R}^2) \left[1 - \cos(2\alpha_R) e^{-2\kappa_1^2 \sigma_\alpha^2} e^{-2\sigma_{\alpha_R}^2} \right] \cdot e^{\kappa_1^2 \sigma_\alpha^2} - \frac{1}{2} (\bar{r}_R^2 + \sigma_{r_R}^2) \left[1 - \cos(2\alpha_R) e^{-2\sigma_{\alpha_R}^2} \right] \quad (27)$$

$$r_{12} = r_{21} = \frac{1}{2} (\bar{r}_R^2 + \kappa_1^2 \sigma_r^2 + \sigma_{r_R}^2) \left[\sin(2\alpha_R) e^{-2\kappa_1^2 \sigma_\alpha^2} e^{-2\sigma_{\alpha_R}^2} \right] \cdot e^{\kappa_1^2 \sigma_\alpha^2} - \frac{1}{2} (\bar{r}_R^2 + \sigma_{r_R}^2) \left[\sin(2\alpha_R) e^{-2\sigma_{\alpha_R}^2} \right] \quad (28)$$

推导出 R_k 后, 使用常规卡尔曼滤波方法, 计算增益因子 K_k 。

$$K_k = \bar{P}_k H_k^T [H_k \bar{P}_k H_k^T + R_k]^{-1} \quad (29)$$

式中, 观测矩阵 $H_k = [I_{2 \times 2} \quad \mathbf{0}_{2 \times 2}]$, $I_{2 \times 2}$ 和 $\mathbf{0}_{2 \times 2}$ 分别代表两行两列的单位阵和零矩阵。

最后修正状态和协方差阵, 完成状态估计。

$$\begin{cases} \hat{\mathbf{x}}_k = \bar{\mathbf{x}}_k + K_k (z_k^{\text{DUCM}} - H_k \bar{\mathbf{x}}_k) \\ \hat{P}_k = \bar{P}_k - K_k H_k \bar{P}_k \end{cases} \quad (30)$$

至此完成一次滤波预测和更新, 当有新的观测到来时, 转到状态预测步骤, 重复以上过程。算法涉及的关键步骤及公式如表1所示。

表1 DUCM改进算法的关键步骤


改进算法步骤	改进算法所用公式
滤波器初始化	式(3)、式(7)
目标状态预测	式(8)~(13)
构造转换量测	式(14)
目标状态更新	式(28)、式(29)

3 仿真分析


将所提DUCM滤波器与经典确定性采样算法无迹卡尔曼滤波(Unscented Kalman Filter, UKF)分别用于外辐射源目标跟踪,进行对比分析。在实际应用中,外辐射源雷达为保证通视,发射站和接收站间距较近。假设接收站位于原点,发射站距离接收站20 km处。双基距离和误差 $\sigma_r = 1\ 000\text{ m}$,方位误差 $\sigma_a = 5^\circ$ 。目标初始位置(0,200) km,全程做(250,0) m/s的近匀速运动,采样周期1 s,蒙特卡洛仿真次数100次,仿真时长300 s。两种方法都采用2.1节所提的初始化方法初始化滤波器。仿真中考核位置均方根误差(Root Mean Square Error, RMSE)和平均归一化估计误差平方(Average Normalized Estimation Error Square, ANEES)指标。为方便对比,在比较平均归一化估计误差平方性能时,采用 $\log_{10}(\text{ANEES})$ 对数指标。RMSE指标的评价标准为数值越小,精度越高。 $\log_{10}(\text{ANEES})$ 的评价标准为数值越接近于0,滤波置信度越高。

首先考察两种算法对低过程噪声目标运动的跟踪性能,在场景1中,目标沿直角坐标系各轴的加速度噪声为 0.1 m/s^2 。仿真对比结果如图2所示。


图2(a)是目标运动轨迹和接收站/发射站的位置部署。在图2(b)中,由于接收站和发射站的间距较近(20 km),因此目标到两站的距离接近,可以观察到所提DUCM算法的双基距离和系数在0.5左右浮动。在135 s之前,方位加权系数保持为1;第150 s开始,逐渐下降至0.55左右,原因在于:跟踪初始阶段,位置误差较大,导致方位预测不准,等效方位误差等于方位观测;随着滤波收敛,方位预测精度逐渐优于方位预测,等效方位误差小于方位观测;在等效距离和等效方位的双重作用下,




(a) 低过程噪声的目标跟踪场景



(b) 双基距离和/方位系数变化曲线



(c) 两种算法的位置跟踪性能对比



(d) 两种算法的 ANEES 跟踪性能对比

图2 低过程噪声场景的跟踪性能对比

图2(c)中所提算法的收敛速度和位置精度都优于UKF,位置精度可达1.7 km以下,滤波置信度也优于UKF(如图2(d)所示),验证了所提算法的优越性。

接着考察两种算法对高过程噪声目标运动的跟踪性能,在场景2中,目标沿直角坐标系各轴的加速度噪声提高到 1 m/s^2 。仿真对比结果如图3所示。


在图3(a)中,由于过程噪声增大,目标的运动轨迹有了更多的不确定性。图3(b)的双基距离和系数曲线与场景1类似,在0.5左右浮动。图3(b)的方位加权系数在150 s之前保持为1,第150 s开始,逐步下降至0.75左右,无论下降开始时间和下降幅度,都不如场景1明显。原因在于:高过程噪声场景中,方位预测精度相对低过程噪声场景(场景1)有所下降,因此所提DUCM算法在方位上的提升作用有所弱化。图3(c)中,所提算法的位置精度优于UKF,精度可达2.2 km,滤波置信度也优于UKF,如图3(d)所示。

综合以上两个场景的仿真结果,所提DUCM算法通过重构出结构简单、非线性更弱、观测误差更小的转换量测模型,提升外辐射源雷达对目标的定位跟踪能力,在不同过程噪声水平下,估计精度和置信度都高于其他经典方法。


4 实测数据分析

在某次试验中,采集民航目标的外辐射源观测数据进行验证。如图4(a)所示,接收站和发射站的间距约为6.7 km,民航飞机向东南方向飞行,时速约为800 km/h,在此过程采集到153个样本,采样周期约2.7 s,外源雷达的双基距离和精度约1 500 m,测向精度约 4.5° 。用所提算法和UKF分别跟踪后,与民航的ADS-B数据比对,结果如图4所示。


在图4(b)中,双基距离和系数约0.5,方位系数在300 s前保持为1,后逐渐减小。由图4(c)可见,DUCM位置精度明显优于UKF。在图4(d)中,两种方法的ANEES接近。该结果验证了算法的工程可用性。




(a) 高过程噪声的目标跟踪场景



(b) 双基距离和/方位系数变化曲线




(c) 两种算法的位置跟踪性能对比




(d) 两种算法的 ANEES 跟踪性能对比


图3 高过程噪声场景的跟踪性能对比




(a) 高过程噪声的目标跟踪场景



(b) 双基距离和/方位系数变化曲线



(c) 两种算法的位置跟踪性能对比



(d) 两种算法的 ANEES 跟踪性能对比

图4 实测场景跟踪性能对比

5 结束语

外辐射源雷达具备低成本、强抗毁特点,能在复杂电磁环境下的电子侦察中发挥重要作用。由于辐射源的非合作特性,外辐射源雷达观测误差较大,需要采用滤波算法提高估计精度。为了在外辐射源雷达中应用去相关无偏转换量测滤波器,提出一种改进的转换量测模型,改进模型中引入更高精度的等效距离和等效方位,因此非线性和复杂度相比原有模型有显著改善。在位置估计精度、滤波置信度和计算量的综合对比中,所提算法优于确定性采样的代表性算法 UKF,仿真和实测数据结果验证了其合理性。

参考文献:

- [1] 万显荣. 基于低频段数字广播电视信号的外辐射源雷达发展现状与趋势[J]. 雷达学报, 2012, 1(2): 109-123.
- [2] 吴宇晨. 基于调频广播信号的外辐射源雷达运动目标探测技术研究[D]. 北京: 北京邮电大学, 2024.
- [3] 王鼎, 尹洁昕, 王叶露, 等. 基于外辐射源雷达系统的运动目标位置与速度解耦估计方法[J]. 电子学报, 2023, 51(11): 3011-3023.
- [4] 韩崇昭. 多源信息融合[M]. 北京: 清华大学出版社, 2010.
- [5] JULIER S J, UHLMANN J K. Reduced Sigma Point Filters for the Propagation of Means and Covariances Through Nonlinear Transformations [C]// 2002 American Control Conference, New York, USA: IEEE, 2002: 887-892.
- [6] ARASARATNAM I, HAYKIN S. Cubature Kalman Filters [J]. IEEE Transactions on Automatic Control, 2009, 54(6): 1254-1269.
- [7] 王法胜, 鲁明羽, 赵清杰, 等. 粒子滤波算法[J]. 计算机学报, 2014, 37(8): 1679-1694.
- [8] BORDONARO S, WILLETT P, BAR-SHALOM Y. Decorrelated Unbiased Converted Measurement Kalman Filter [J]. IEEE Transactions on Aerospace and Electronic Systems, 2014, 50(2): 1431-1444.
- [9] 盛璇, 汪海兵, 王杰. 基于转换量测重构的组网雷达融合方法[J]. 现代雷达, 2025, 47(2): 52-57. (下转第41页)

基于混合策略改进 DBO 的多无人机协同干扰策略

李家强, 喻庞泽, 李淑君, 陈金立, 姚昌华

(南京信息工程大学电子与信息工程学院, 江苏南京 210044)

摘要: 针对多无人机协同干扰组网雷达任务中资源分配导致的干扰效能低下问题, 提出一种基于增强型蜣螂优化算法的干扰资源协同优化方法。首先, 构建多维干扰资源协同优化模型, 涵盖波束指向与功率分配的联合优化; 其次, 在算法设计层面实施三重改进: 采用 Tent 混沌映射增强种群初始化多样性, 改善算法全局探索能力; 在偷窃蜣螂位置更新阶段引入柯西-高斯双模变异机制, 通过参数自适应调整平衡局部开发精度; 构建环境反馈驱动的种群自适应调节机制, 基于迭代优化效率动态调整种群结构。实验仿真结果表明本文所提算法能够显著提升算法的收敛速度和全局寻优能力。

关键词: 无人机协同干扰; 蜣螂优化算法; 柯西-高斯变异; 环境反馈机制

中图分类号: TN974

文献标志码: A

文章编号: 1672-2337(2026)01-0022-09

引用格式: 李家强, 喻庞泽, 李淑君, 等. 基于混合策略改进 DBO 的多无人机协同干扰策略[J]. 雷达科学与技术, 2026, 24(1): 22-30.

LI Jiaqiang, YU Pangze, LI Shujun, et al. Multi-UAV Cooperative Jamming Strategy Based on Hybrid Strategy Improved DBO[J]. Radar Science and Technology, 2026, 24(1): 22-30.

Multi-UAV Cooperative Jamming Strategy Based on Hybrid Strategy Improved DBO

LI Jiaqiang, YU Pangze, LI Shujun, CHEN Jinli, YAO Changhua

(School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Aiming at the problem of low jamming effectiveness caused by resource allocation in multi-UAV cooperative jamming missions against networked radar systems, a cooperative optimization method of jamming resources based on enhanced dung beetle optimization algorithm is proposed. Firstly, a multi-dimensional interference resource cooperative optimization model is constructed, integrating joint optimization of beam steering and power allocation. Secondly, three algorithmic enhancements are implemented: Tent chaotic mapping is adopted to enhance population initialization diversity, improving the global exploration capabilities; the Cauchy-Gaussian dual-mode mutation mechanism is introduced during the position update phase of stealing dung beetles, achieving balanced local exploitation precision through parameter self-adaptation; an environmental feedback-driven population adaptation mechanism is established to dynamically adjust population structure based on iterative optimization efficiency. Experimental simulation results demonstrate that the proposed algorithm significantly improves the convergence speed and global optimization capability.

Key words: UAV cooperative jamming; dung beetle algorithm; Cauchy-Gaussian mutation; environmental feedback mechanism

0 引言

电磁战中的干扰是电子攻击的一部分, 目的是通过向敌方的通信、雷达和导航系统中发射电磁能量, 阻碍或削弱其正常工作, 从而削弱敌方的指挥、控制和作战能力^[1-2]。电磁攻击通常采用噪声压制干扰和欺骗干扰, 通过发射强大的干扰信

号掩盖雷达回波, 从而降低敌方雷达对己方作战单位的探测概率^[3-4]。尽管组网雷达通过数据融合以及资源分配能有效地实现对目标的探测^[5-6], 电子对抗形式也不再是简单的“一对一”和“多对一”, 而是“多对多”的对抗形式, 多干扰机协同作战往往能更好地适应现代化战争中复杂的作战环境并完成干扰任务^[7-8], 但是干扰资源总是有限的,

如何对有限的干扰资源合理优化分配,是实现更好干扰效果的关键。

无人机干扰资源分配问题是一个非连续多参数多约束的问题。传统的组合优化方法能够解决小规模干扰资源分配问题,但随着对抗双方规模的扩大以及干扰资源的多样性,传统的方法很难去解决。为了解决干扰波束分配问题,有学者考虑干扰对象的威胁等级以及干扰效果,利用运筹学中的0-1规划,但该方法无法解决连续变量的功率分配问题^[9]。元启发式算法是根据一些生物种群中的特殊行为抽象出来的算法,它可以广泛地用于解决一些复杂的优化问题。这些算法的核心思想是通过在搜索空间中不断搜索,然后逐步逼近问题的最优解。Sun等人^[10]利用群体智能算法优化无人机的飞行任务,实现了多机协同对组网雷达系统进行欺骗干扰。Zou等人^[11]建立干扰效益评估矩阵,通过组合搜索策略和改进的二进制粒子群算法对干扰波束进行了分配,虽然优化结果波动幅度非常稳定,寻优能力相对来说比较一般。文献^[12]通过评估辐射源危险等级和干扰效能,建立干扰资源分配模型,并利用改进的萤火虫算法搜索最优分配方案。文献^[13]建立了包含干扰波束和发射功率的干扰资源分配模型,并分别利用改进遗传算法对该模型进行优化求解。但他们都仅考虑了干扰机静态时的优化结果,但实际对抗时需要考虑多帧动态的情况。有学者利用人工蜂群算法分两步分别分配干扰波束和干扰功率资源^[14]。但人工蜂群算法对于参数设置比较敏感,在动态环境中可能无法适应变化,导致解的质量下降。

为了实现更好的有限干扰资源优化效果,本文将蜣螂优化算法^[15]应用于无人机协同干扰资源分配问题的求解。蜣螂优化算法能够适应不同类型的优化问题,包括连续和离散问题,所以它常被学者用于求解资源分配等问题。然而,蜣螂优化算法本身也存在一定局限性,如在搜索空间较大且分布不均匀时,算法容易陷入局部最优,且收敛速度相对较慢。为此,本文通过优化种群初始化策略对算法进行了改进,并引入柯西-高斯变异策略和环境反馈机制自适应模型,得到了更加优化

的干扰资源分配结果,显著提升了算法的收敛速度和全局寻优能力。

1 多无人机协同干扰组网雷达模型

假设在某次突防任务中,组网雷达由 N 部地面雷达 $\{R_1, R_2, \dots, R_N\}$ 组成,无人机由 K 架突防无人机 $\{Q_1, Q_2, \dots, Q_K\}$ 和 M 架干扰无人机 $\{J_1, J_2, \dots, J_M\}$ 组成。 M 架干扰无人机用于干扰 N 部雷达,从而掩护 K 架突防无人机接近雷达完成突防任务,如图1所示。




图1 多无人机协同干扰组网雷达模型

1.1 干扰无人机波束分配模型

干扰无人机波束分配模型为:在某一时刻可以发射多个干扰波束,每个波束只能指向单部雷达,单部雷达在同一时刻可以受到多个干扰波束的干扰。那么可以定义多架干扰无人机在 t 时刻的干扰波束分配矩阵,如式(1)所示:

$$\mathbf{u}^t = \begin{bmatrix} u_{1,1}^t & u_{1,2}^t & \cdots & u_{1,N}^t \\ u_{2,1}^t & u_{2,2}^t & \cdots & u_{2,N}^t \\ \vdots & \vdots & & \vdots \\ u_{M,1}^t & u_{M,2}^t & \cdots & u_{M,N}^t \end{bmatrix} \quad (1)$$

式中, $u_{m,n}^t$ 表示干扰无人机 m 在第 t 时刻对第 n 个雷达发射的干扰波束,当 $u_{m,n}^t$ 为“1”时表示干扰无人机 m 分配波束干扰雷达 n ,当 $u_{m,n}^t$ 为“0”时表示干扰无人机 m 不分配波束给干扰雷达 n 。

假定每架干扰机 m 能产生 L 个波束,规定一个干扰波束在 t 时刻只能指向一个雷达且单部雷达在同一时刻可以受到不低于1个干扰波束的干扰。上述约束模型的数学公式如式(2)所示:

$$\begin{cases} \sum_{n=1}^N u_{m,n}^t = L, m = 1, 2, \dots, M, t = 1, 2, \dots, T \\ \sum_{m=1}^M u_{m,n}^t \geq 1, n = 1, 2, \dots, N, t = 1, 2, \dots, T \end{cases} \quad (2)$$

1.2 功率分配模型

设每架干扰无人机的干扰波束的发射功率可控,那么定义干扰无人机在第 t 时刻的干扰功率分配矩阵为

$$P^t = \begin{bmatrix} P_{1,1}^t & P_{1,2}^t & \dots & P_{1,N}^t \\ P_{2,1}^t & P_{2,2}^t & \dots & P_{2,N}^t \\ \vdots & \vdots & & \vdots \\ P_{M,1}^t & P_{M,2}^t & \dots & P_{M,N}^t \end{bmatrix} \quad (3)$$

式中, $P_{m,n}^t$ 表示干扰无人机 m 在第 t 时刻对第 n 个雷达发射的干扰波束的功率,当 $P_{m,n}^t > 0$ 时,表示干扰无人机 m 对雷达 n 存在干扰。

假定每个干扰机的总功率最大为 P_m^{total} ,每个波束的发射功率大于等于0且不大于最大功率 P_m^{total} ,则功率分配模型的数学公式如式(4)所示:

$$\begin{cases} \sum_{n=1}^N P_{m,n}^t = P_m^{\text{total}}, m = 1, 2, \dots, M \\ 0 \leq P_{m,n}^t \leq P_m^{\text{total}}, m = 1, 2, \dots, M \end{cases} \quad (4)$$

1.3 雷达探测模型

雷达通过发射信号和接收回波信号来探测目标,雷达工作模式主要有搜索模式和跟踪模式,其中搜索模式特征是大范围扫描,低重频,所以本文采用大功率噪声压制干扰策略着重对搜索模式进行攻击。为了简化模型的复杂性并且有效地评估干扰资源分配结果,从一个施放干扰者的角度出发,本文选择基于探测概率的目标函数模型,用噪声干扰下的雷达对目标的探测概率作为评价指标。

若雷达未受到干扰,其探测概率的主要影响因素由雷达接收机内部的热噪声 N_r 产生,数学公式为

$$N_r = KT_0 B_r F \quad (5)$$

式中, K 是玻耳兹曼常数,值为 1.38×10^{-23} J/K, T_0 是标准温度,值为290 K, B_r 是噪声带宽, F 是噪声系数。

假设每部雷达的发射功率、工作频段等工作

参数都相同,在未受到干扰时的第 n 个雷达在第 t 时刻探测目标 q 时接收到的回波信号的功率公式如式(6)所示:

$$Pr_{n,q}^t = \frac{Pt_n Gt_n Gt_n \lambda_n^2 \sigma_{n,q}^t}{(4\pi)^3 (R_{n,q}^t)^4 L_n} \quad (6)$$

式中, Pt_n 是雷达的发射功率, Gt_n 是雷达的天线增益, λ_n 是雷达的工作波长, $\sigma_{n,q}^t$ 是目标 q 被雷达 n 探测的雷达散射截面积(RCS), $R_{n,q}^t$ 是雷达 n 与目标 q 之间在 t 时刻的距离, L_n 是雷达的系统损失系数。

雷达 n 在 t 时刻探测目标 q 的信噪比可表示为

$$SNR_{n,q}^t = \frac{Pr_{n,q}^t}{N_r} \quad (7)$$

当雷达被干扰时,对于雷达探测概率的影响由受到的干扰信号和热噪声共同产生,在受到干扰时的第 n 个雷达在第 t 时刻探测目标 q 时接收到的干扰信号的功率为

$$Pr_{m,n}^{j,t} = \frac{Pj_m Gj_m Gt_n \lambda_m^2 \gamma_m \Delta f_r}{(4\pi)^2 (Rj_{m,n}^t)^2 L_m \Delta f_m} P_{m,n}^t u_{m,n}^t \quad (8)$$

式中, Pj_m 是干扰机的总发射功率, Gj_m 是干扰机的发射增益, λ_m 是干扰信号的波长, γ_m 是干扰信号对雷达天线的极化系数, $Rj_{m,n}^t$ 是雷达和干扰无人机之间的距离, $\frac{\Delta f_r}{\Delta f_m}$ 表示干扰信号与雷达信号的频率重合程度, L_m 是干扰系统的损失系数。

当有两个干扰信号 $s_1(t)$ 和 $s_2(t)$,其总信号为: $s(t) = s_1(t) + s_2(t)$,则总功率为: $P_{\text{total}} = E[|s(t)|^2] = E[|s_1(t)|^2] + E[|s_2(t)|^2] + 2 \cdot \text{Re}\{E[s_1(t)s_2^*(t)]\}$ 。若信号互不相干,则 $E[s_1(t)s_2^*(t)] = 0$ 。此时多节点在同一雷达处信号叠加模型可以简化为干扰信号的线性叠加,无须考虑相位相互作用。所以在受到干扰时的第 n 个雷达在第 t 时刻探测目标 q 时接收到的回波信号的信干噪比如式(9)所示:

$$SINR_{n,q}^t = \frac{Pr_{n,q}^t}{\sum_{m=1}^M (u_{m,n}^t Pr_{m,n}^{j,t}) + N_r} \quad (9)$$

由于雷达探测概率、虚警概率和接收信号信噪比之间存在一定的函数关系,为了简化探测概率 P_d 的计算,假设所有目标均为Swerling I型,不考虑脉冲重复积累。那么目标 q 在 t 时刻被雷达 n 发现的概率近似为

$$Pd_{n,q}^t = e^{\frac{\alpha}{1 + SINR_{n,q}^t}} \quad (10)$$

式中, α 为检测阈值与虚警概率有关 P_{fa} 的函数, $\alpha = 0.3 \ln P_{fa}$ 。

敌方雷达系统在面临电子干扰时,通常会采用多种协同抗干扰策略来提升其战场生存能力和探测效能。其中常用空间协同抗干扰,通过多部雷达组网雷达协同,比如分布式部署,因此将这种抗干扰方式建模。根据OR准则,即只要雷达系统的任意一次检测报告中目标存在,系统就判定目标存在,则组网雷达在 t 时刻对目标 q 的探测概率可以表示为

$$Pd_q^t \triangleq 1 - \prod_{n=1}^N (1 - Pd_{n,q}^t) \quad (11)$$

本文将检测概率的最小值转化为求解的适应度最大值,目标函数定义为组网雷达对所有目标探测概率的倒数和,即

$$\max F = \sum_{q=1}^K \frac{1}{Pd_q^t} \quad (12)$$

2 基于改进蜣螂算法的干扰资源分配方法

2.1 标准蜣螂算法

蜣螂优化算法(Dung Beetle Optimizer, DBO)是一种仿生启发式优化算法,与蚁群算法、粒子群算法等类似,通过模拟这种生物的搜索食物和搬运粪球的方式,来解决全局优化问题。

该算法主要分有4个行为模式,具体如下:

1) 滚球行为

蜣螂会滚动粪球,并不断调整方向,对应到优化算法中,个体会在解空间中根据其当前位置和目标位置进行移动。在滚动过程中,按式(13)对位置即干扰波束分配或干扰功率策略进行更新:

$$x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x \quad (13)$$

式中, t 表示当前的迭代次数, $x_i(t)$ 表示第 i 只蜣螂在第 t 次迭代时的位置信息, k 是个常数,表示偏转系数, $\alpha \in (0,1)$ 是一个随机数, b 是一个自然系数,为-1或1, Δx 为当前位置与全局最差位置 X^w 的差值,其表达式为 $\Delta x = |x_i(t) - X^w|$ 。

2) 跳舞行为

当蜣螂遇到障碍物时,它会通过跳舞来重新

定向即重新寻找新的干扰资源分配策略,主要是通过正切函数来进行位置更新:

$$x_i(t+1) = x_i(t) + \tan \theta |x_i(t) - x_i(t-1)| \quad (14)$$

式中, $\tan \theta$ 为偏转角。

3) 繁殖行为

原算法提出了一种边界选择策略来模拟雌性蜣螂产卵的区域即干扰资源分配寻优范围,如式(15)所示:

$$\begin{cases} Lb^* = \max(X^* \times (1 - R), Lb) \\ Ub^* = \min(X^* \times (1 + R), Ub) \end{cases} \quad (15)$$

式中, X^* 为本次迭代当前的最佳位置, Lb 表示下界, Ub 表示上界, $R = 1 - \frac{iter}{MaxIteration}$, $iter$ 为当前迭代轮次, $MaxIteration$ 为最大迭代次数。

在迭代过程中,卵球的位置即干扰资源分配策略变化如式(16)所示:

$$B_i(t+1) = X^* + b_1 \times (B_i(t) - Lb^*) + b_2 \times (B_i(t) - Ub^*) \quad (16)$$

式中, B_i 表示卵球的位置, b_1 和 b_2 为随机向量。

新出生的小蜣螂会出来觅食,同样采用了边界选择策略来规定最优觅食区域来引导小蜣螂,数学公式为

$$\begin{cases} Lb^b = \max(X^b \times (1 - R), Lb) \\ Ub^b = \min(X^b \times (1 + R), Ub) \end{cases} \quad (17)$$

式中, X^b 表示全局最佳位置, Lb^b 和 Ub^b 分别为最优觅食区域的上界和下界, $R = 1 - \frac{iter}{MaxIteration}$, $iter$ 为当前迭代轮次, $MaxIteration$ 为最大迭代次数。

小蜣螂的位置更新可表示为

$$x_i(t+1) = x_i(t) + C_1 \times (x_i(t) - Lb^b) + C_2 \times (x_i(t) - Ub^b) \quad (18)$$

式中, C_1 表示服从正态分布的随机数, C_2 是属于 $(0,1)$ 的随机向量。

4) 偷窃行为

部分蜣螂会从其他蜣螂那偷粪球,这种偷窃行为对应的蜣螂位置更新即干扰分配策略更新可表示为

$$x_i(t+1) = X^b + S \times g \times (|x_i(t) - X^b| + |x_i(t) - X^b|) \quad (19)$$

式中, g 是服从均值为0、方差为1的正态分布, S 是一个常数。

2.2 蜣螂算法改进策略

标准的蜣螂算法会存在寻优能力差、易陷入局部最优问题,改进的蜣螂算法(Improved Dung Beetle Optimizer, IDBO)流程如图2所示,主要包括如下3个部分。




图2 改进的蜣螂算法流程图

2.2.1 混沌映射初始化

在原算法中,种群初始化阶段初始化种群的位置是随机分布的,往往会导致初始化种群多样性较差,进一步会使算法在寻优阶段容易陷入局部最优。而混沌映射初始化能够保证初始化种群在解空间中全面覆盖,从而能够提高寻找到最优解的概率^[16]。本文使用Tent映射来初始化。Tent映射是一种简单的非线性映射,用于产生混沌行为^[17]。其数学公式为

$$x_{n+1} = \begin{cases} \mu x_n, & x_n < 0.5 \\ \mu(1 - x_n), & x_n \geq 0.5 \end{cases} \quad (20)$$

式中 μ 是映射的参数,通常在(0,2)范围内,参数值不同会产生不同的行为。特别是当 $\mu = 2$ 时,系统会表现出典型的混沌特性。

2.2.2 二阶段柯西-高斯变异策略

由于原算法中存在边界选择策略的原因,即规定了个体每次干扰资源分配策略的更新范围,所以原算法在获得较快收敛速度的同时也导致了

容易陷入局部最优,所以本文在不损失收敛速度的同时,提出一种二阶段的柯西-高斯变异策略,通过在算法后期引入新的变异策略,增强算法跳出局部最优的能力,防止算法陷入局部最优。本文在柯西-高斯变异的基础上改进,将其分为两个阶段,定义为

$$x_i(t+1) = \begin{cases} X^b + \text{Cauchy} \times X^b, & \text{iter} \leq \frac{\text{MaxIteration}}{2} \\ X^b \times \text{Gaussian}, & \text{iter} > \frac{\text{MaxIteration}}{2} \end{cases} \quad (21)$$

式中, Cauchy 是一个服从柯西分布的随机变量, Gaussian 是一个服从高斯分布的随机变量。

设定一个变异概率 α ,当随机数 R 小于 α 时,调用上述变异策略。在迭代初期需要较大的寻优范围,选择柯西变异,因为其变异值有较大的跳跃^[18],有利于跳出当前位置。在迭代后期,则需要尽快使优化过程收敛,选择高斯变异,因为其变异值较为平滑^[19],有利于保持在最优位置附近进行局部扰动。

2.2.3 基于环境反馈的自适应模型

由于DBO算法初始化时会对负责不同行为的蜣螂进行分组,但是原算法对于蜣螂行为分组的比例是固定的,这可能会导致算法前期寻优速度缓慢和寻优能力差,后期收敛缓慢等问题。为了解决这一问题,本文提出一种基于环境反馈的自适应模型。即在每轮迭代结束时,统计这一轮迭代新产生出 count 个目标函数值比原种群更好的个体数量,计算 count 在种群数量 pop 中的占比 $\frac{\text{count}}{\text{pop}}$,这个值越大表明蜣螂的食物越充足,即当前存在更优干扰资源分配结果的概率越大。这里设定一个判定阈值 β ,当 $\frac{\text{count}}{\text{pop}} > \beta$ 时,那么就需要增加负责繁衍行为的个体数量,当 $\frac{\text{count}}{\text{pop}} \leq \beta$ 时需要减少负责繁衍行为的个体数量。

2.3 基于改进蜣螂优化算法的求解步骤

由公式(8)可知,本文模型存在两个变量干扰波束分配矩阵 $\mathbf{u}'$ 和干扰功率分配矩阵 $\mathbf{P}'$,其中 $\mathbf{u}'$ 为离散值, $\mathbf{P}'$ 为连续值,且两者以乘积形式出现,若直接对其求解比较困难,则本文利用改进蜣螂优化算法对多无人机协同干扰组网雷达模型进行两

步求解,具体步骤如下:

步骤1:首先求解干扰无人机的干扰波束指向,即干扰波束分配结果 $\mathbf{u}'$,假设每个波束的发射功率均匀分配 $P'_{m,n} = \frac{P_m^{\text{total}}}{N}$,此时优化问题的变量仅为干扰波束分配结果。优化问题转变为,在干扰功率分配固定时,求解使公式(11)函数值最大情况下的 $\mathbf{u}'$,利用优化算法对公式(1)~(11)进行求解,可以求出原优化问题的松弛结果 $\mathbf{u}'$ 。

步骤2:在求得 $\mathbf{u}'$ 的基础上求解干扰无人机发射功率,即干扰功率分配结果 $\mathbf{P}'$,由于此时的波束分配为第一步求得的松弛结果,优化问题的变量仅为干扰功率分配。优化问题转变为,在干扰波束分配固定时,求解使公式(11)函数值最大情况下的 $\mathbf{P}'$,同理运用改进蜣螂算法对公式(1)~(11)进行求解,即可求出最终优化的结果 $\mathbf{P}'$ 。

3 仿真实验结果与分析

3.1 仿真实验参数设置

为了验证文章提出的改进策略算法的有效性,本节进行实例分析。假设当前电子对抗模型,敌方有6部工作参数相同的雷达构成雷达组网,我方有2架突防无人机需要完成突防任务,派出3架工作参数相同的干扰无人机对敌方雷达进行干扰,每部干扰无人机可同时发射3道干扰波束。雷达、突防无人机和干扰无人机的运动参数信息如表1所示。表2和表3分别为雷达的工作参数和干扰无人机的工作参数。假设无人机的雷达散射面积(RCS)都为 1 m^2 。

表1 模型的运动参数

模型	初始位置/m	速度/($\text{m} \cdot \text{s}^{-1}$)
突防无人机1	(10 500, 3 000, 1 200)	(100, 0, 15)
突防无人机2	(10 500, 3 100, 1 200)	(100, 0, 15)
干扰无人机1	(11 000, 3 300, 1 200)	(100, 0, 15)
干扰无人机2	(11 500, 2 800, 1 200)	(100, 0, 15)
干扰无人机3	(12 000, 3 200, 1 200)	(100, 0, 15)
雷达1	(500, 2 000, 0)	(0, 0, 0)
雷达2	(700, 2 500, 0)	(0, 0, 0)
雷达3	(600, 3 000, 0)	(0, 0, 0)
雷达4	(900, 3 500, 0)	(0, 0, 0)
雷达5	(200, 4 000, 0)	(0, 0, 0)
雷达6	(500, 4 500, 0)	(0, 0, 0)

表2 雷达工作参数表

参数	参数值
发射功率/W	200×10^6
发射增益/dB	10
带宽/Hz	10×10^6
工作波长/m	0.1
损失系数/dB	6
噪声系数/dB	3
虚警概率	1×10^{-6}


表3 干扰无人机工作参数表

参数	参数值
发射功率/W	120
发射增益/dB	10
带宽/Hz	10×10^6
干扰信号对雷达天线的极化系数	0.5
工作波长/m	0.1
损失系数/dB	6


蜣螂优化算法初始参数设置为:最大迭代次数200次,种群数量50,滚球行为蜣螂占比为0.3,跳舞行为蜣螂占比为0.3,繁殖行为蜣螂占比为0.2,偷窃行为蜣螂占比为0.2,变异概率 α 为0.2,种群占比改变阈值 β 为0.3。

3.2 仿真实验结果


按照2.3节对步骤1进行求解,图3为前10帧干扰无人机波束分配结果,其中横坐标为帧数,纵坐标表示雷达编号,黄色代表此时此刻干扰无人机的干扰波束指向该雷达,蓝色表示此时此刻干扰无人机对该雷达不存在干扰。图中干扰机1在第1帧时产生了3个干扰波束分别分配给了雷达1、雷达2和雷达6,干扰机2在第1帧时产生了3个干扰波束分别分配给了雷达3、雷达4和雷达5,干扰机3在第1帧时产生了3个干扰波束分别分配给了雷达3、雷达4和雷达5。



(a) 干扰机1




(b) 干扰机2




(c) 干扰机3

图3 波束分配结果


在求得波束分配结果后,通过2.3节对步骤2进行求解,图4为前10帧干扰无人机功率分配结果,图中不同的颜色表示归一化后的功率值。从图中可以看出对于没有波束照射的雷达,功率都为0,同时保证了每一部雷达在任意时刻都能至少被一部干扰无人机所干扰。



(a) 干扰机1



(b) 干扰机2



(c) 干扰机3

图4 干扰资源分配结果

利用遗传算法(Genetic Algorithm, GA)^[13]、蝴蝶优化算法(Butterfly Optimization Algorithm, BOA)^[20]、蜣螂优化算法(DBO)^[15]以及本文所提算法(IDBO)分别对多无人机协同干扰模型进行仿真,利用这些算法得到的初始时刻的优化过程曲线如图5所示。




图5 改进DBO算法与传统算法收敛曲线对比

实验结果图5表明改进蜣螂优化算法IDBO相对于原始DBO算法,在算法收敛速度方面有显著提升,改进蜣螂算法在20代时就收敛到最大值10.398 497 98,而其他算法都明显落后,这得益于对蜣螂占比的动态调整。在食物充足时,即当前存在更优干扰资源分配结果的概率越大时,增加了繁殖行为蜣螂的数量即增加了此时算法的局部开发能力;反之,减少繁殖行为蜣螂的数量,避免了算法陷入局部最优。在寻优能力方面,改进蜣螂算法在收敛时,收敛在了更大的目标函数,这证明了在算法后期使用柯西-高斯变异策略的有效性,增强了算法防止陷入局部最优的能力。

对各算法分别进行200次蒙特卡洛仿真,改进后的蜣螂优化算法和其他算法的目标函数的最大

值、平均值和方差如表4所示。仿真结果表明,蛱螂优化算法与改进蛱螂优化算法在最大值和平均值方面都明显高于GA算法和BOA算法,而在方差指标中IDBO也优于DBO。由此可以看出改进后的蛱螂优化算法在具有不错寻优能力的同时,在鲁棒性方面相对于改进前的蛱螂优化算法也得到了明显的改善。

表4 算法性能分析表

算法	最大值	平均值	方差
GA	10.398 81	10.397 69	4.406×10^{-7}
BOA	10.398 95	10.397 92	1.243×10^{-6}
DBO	10.399 18	10.398 20	6.169×10^{-7}
IDBO	10.399 19	10.398 55	5.915×10^{-7}

假定无人机和雷达的加速度都为0,位置和速度参数如表1所示,现对整个对抗过程进行仿真,整个过程总共为80帧,其中每帧的时间为1s,利用改进蛱螂优化算法求出每一时刻的干扰波束分配以及干扰功率分配,利用公式(5)~(10),求出在受到干扰和未受到干扰时突防目标1、2被雷达探测到的概率,其曲线如图6所示。




图6 目标1、2受干扰和未受干扰时的探测概率

实验结果表明,在没有干扰的情况下组网雷达对于目标1和目标2的探测概率都始终为1,所以导致了图中未受干扰时目标1被探测到的概率和未受干扰时目标2被探测到的概率的曲线重合。在存在干扰的情况下,电子对抗初期,组网雷达对于目标的探测概率为0.2,随着时间的增加,目标越来越靠近雷达,探测概率越来越大,曲线总体呈上升趋势,验证本文干扰模型能够有效影响雷达探测概率。

4 结束语

本文针对无人机协同干扰组网雷达时,干扰无人机利用有限的干扰资源协助突防无人机完成突防任务所产生的干扰资源分配问题,建立了基于雷达探测概率的干扰资源分配模型。采用改进的蛱螂优化算法对问题模型进行求解,通过混沌映射初始化提升了算法的寻优能力,增加二阶段的柯西-高斯变异策略,防止算法陷入局部最优,并引入环境反馈机制自适应模型,提升了算法的收敛速度。仿真结果表明本文算法在处理该模型时比其他方法能更有效地得到干扰资源分配结果,同时对于动态的对抗过程进行仿真,实验结果表明该协同干扰模型能有效地对雷达产生影响,降低雷达探测概率。

参考文献:

- [1] 汪清,陈琪,王浩智,等.未知博弈范式下的通用电磁对抗策略自动生成研究[J].电子与信息学报,2023,45(11):4072-4082.
- [2] XIN Qi, XIN Zengxian, CHEN Tao. Cooperative Jamming Resource Allocation with Joint Multi-Domain Information Using Evolutionary Reinforcement Learning [J]. Remote Sensing, 2024, 16(11):1955.
- [3] ZHANG Chudi, WANG Lei, JIANG Rundong, et al. Radar Jamming Decision-Making in Cognitive Electronic Warfare: A Review[J]. IEEE Sensors Journal, 2023, 23(11): 11383-11403.
- [4] 王跃东,顾以静,梁彦,等.伴随压制干扰与组网雷达功率分配的深度博弈研究[J].雷达学报,2023,12(3):642-656.
- [5] QI Cheng, ZHANG Haowei, XIE Junwei, et al. Cooperative Game Theoretic Power Allocation Method to Distributed MIMO Radar Sensor Network for Multitarget Detection in Low-Altitude[J]. IEEE Sensors Journal, 2024, 24(6): 8731-8745.
- [6] LI Zhengjie, XIE Junwei, ZHANG Haowei, et al. Joint Target Assignment and Power Allocation in the Netted C-MIMO Radar When Tracking Multi-Targets in the Presence of Self-Defense Blanket Jamming [J]. Defence Technology, 2023, 24(1):414-427.
- [7] 任智,张栋,唐硕,等.无人机集群反制与对抗技术探讨[J].指挥与控制学报,2023,9(6):660-672.

- [8] 吕茂隆,段海滨,杨任农,等.无人机集群空中博弈对抗体系指挥控制模型[J].指挥与控制学报,2024,10(4):401-411.
- [9] 沈阳,陈永光,李修和.基于0-1规划的雷达干扰资源优化分配研究[J].兵工学报,2007,28(5):528-532.
- [10] SUN Jun, YUAN Ye, GRECO M S, et al. Coordinated Deception Jamming Power Scheduling for Multijammer Systems Against Distributed Radar Systems[J]. IEEE Trans on Radar Systems, 2024(2):1076-1088.
- [11] ZOU Weiqi, NIU Chaoyang, LIU Wei, et al. Combination Search Strategy-Based Improved Particle Swarm Optimization for Resource Allocation of Multiple Jammers for Jamming Netted Radar System[J]. IET Signal Processing, 2023, 17(4):12198.
- [12] XING Huaixi, WU Hua, CHEN You, et al. A Cooperative Interference Resource Allocation Method Based on Improved Firefly Algorithm[J]. Defence Technology, 2021, 17(4):1352-1360.
- [13] 陈思南.一种对抗雷达组网的干扰目标分配方法[J].雷达科学与技术,2023,21(4):454-459.
- [14] XING Huaixi, XING Qinghua, WANG Kun. A Joint Allocation Method of Multi-Jammer Cooperative Jamming Resources Based on Suppression Effectiveness[J]. Mathematics, 2023, 11(4):826.
- [15] XUE Jiankai, SHEN Bo. Dung Beetle Optimizer: A New Meta-Heuristic Algorithm for Global Optimization[J]. The Journal of Supercomputing, 2023, 79(7):7305-7336.
- [16] HE Juncai, HE Zhenxue, LIU Jia, et al. An Effective Power Optimization Approach Based on Whale Optimization Algorithm with Two-Populations and Mutation Strategies[J]. Chinese Journal of Electronics, 2024, 33(2):423-435.
- [17] LIU Tianqi, YANG Hua, YU Jing, et al. A Global Harmony Search Algorithm Based on Tent Chaos Map and Elite Reverse Learning[C]//2022 14th International Conference on Advanced Computational Intelligence, Wuhan, China: IEEE, 2022: 320-325.
- [18] ZHAO Xiaodong, FANG Yiming, LIU Le, et al. A Covariance-Based Moth-Flame Optimization Algorithm with Cauchy Mutation for Solving Numerical Optimization Problems[J]. Applied Soft Computing, 2022(119):108538.
- [19] ZHANG Xiang, XU Yueting, YU Caiyang, et al. Gaussian Mutational Chaotic Fruit Fly-Built Optimization and Feature Selection[J]. Expert Systems with Applications, 2020(141):112976.
- [20] 陈振坤,程嗣怡,刘丹,等.基于改进蝴蝶算法的协同干扰资源分配方法[J].现代雷达,2023,45(3):98-106.

作者简介:

李家强(通信作者) 男,博士,副教授,主要研究方向为信号检测与估计、数据处理目标跟踪与成像。

喻庞泽 男,硕士研究生,主要研究方向为多无人机协同干扰。

李淑君 女,硕士研究生,主要研究方向为雷达抗干扰。

陈金立 男,博士,教授,主要研究方向为信号处理与数据分析。

姚昌华 男,博士,教授,主要研究方向为智能无人集群和电磁频谱对抗。

基于降维累积量和矩阵重构的相干 DOA 估计

刘宁庄¹, 侯志凯¹, 符渭波², 田海波³

(1. 西安科技大学电气与控制工程学院, 陕西西安 710000; 2. 西安科技大学通信与信息工程学院, 陕西西安 710000;
3. 西安科技大学机械工程学院, 陕西西安 710000)

摘要: 针对复杂电磁环境中因低信噪比、快拍采样数据不足、非高斯杂波干扰及多径传播效应等导致的波达方向(Direction of Arrival, DOA)估计性能退化问题,本文提出了一种基于降维高阶累积量与低秩矩阵重构的多源相干信号的 DOA 估计算法。首先通过构建四阶累积量矩阵扩展阵列孔径,抑制高斯噪声,提升欠定条件下的信号自由度;随后采用高效的降维策略,显著降低计算复杂度;最后通过交替方向乘子法求解低秩约束下的 Toeplitz 协方差矩阵重构问题,实现了复杂环境下多源相干信号的高精度定位。实验结果表明,本算法在低信噪比及少快拍数下对多源相干信号依然有出色的估计性能,兼具高精度和强抗干扰特性,有良好的工程实用价值。

关键词: 阵列信号处理; 相干 DOA 估计; 高阶累积量; 降维变换; 交替方向乘子法

中图分类号: TN911.7

文献标志码: A

文章编号: 1672-2337(2026)01-0031-11

引用格式: 刘宁庄, 侯志凯, 符渭波, 等. 基于降维累积量和矩阵重构的相干 DOA 估计[J]. 雷达科学与技术, 2026, 24(1): 31-41.

LIU Ningzhuang, HOU Zhikai, FU Weibo, et al. Coherent DOA Estimation Based on Reduced-Dimensional Cumulants and Matrix Reconstruction[J]. Radar Science and Technology, 2026, 24(1): 31-41.

Coherent DOA Estimation Based on Reduced-Dimensional Cumulants and Matrix Reconstruction

LIU Ningzhuang¹, HOU Zhikai¹, FU Weibo², TIAN Haibo³

(1. College of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710000, China;
2. College of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710000, China;
3. College of Mechanical Engineering, Xi'an University of Science and Technology, Xi'an 710000, China)

Abstract: In this paper, a direction of arrival (DOA) estimation method for multi-source coherent signals based on reduced-dimensional higher-order cumulants and low-rank matrix reconstruction is proposed to improve the performance of DOA estimation in radar systems caused by low signal-to-noise ratio (SNR), insufficient snapshot sampling data, non-Gaussian clutter interference, and multipath propagation effects in complex electromagnetic environments. Firstly, by constructing a fourth-order cumulant matrix, the array aperture is expanded to suppress Gaussian noise. Then, an efficient reduced-dimensional strategy is employed to reduce computational complexity. Finally, the alternating direction method of multipliers is used to solve the reconstruction problem of Toeplitz covariance matrix under low-rank constraints, achieving high-precision localization of multi-source coherent signals in complex environments. Experimental results demonstrate that the proposed algorithm maintains excellent estimation performance for multi-source coherent signals under low SNR and limited snapshots, combining high accuracy and strong anti-interference capabilities.

Key words: array signal processing; coherent direction of arrival (DOA) estimation; higher-order cumulants; reduced-dimensional transformation; alternating direction multiplier method

0 引言

近年来,随着雷达、无线通信、声呐和地震勘探等领域对信号处理技术的不断追求,波达方向

(Direction of Arrival, DOA)估计问题逐渐成为学术界和工业界研究的热点。传统的 DOA 估计算法例如旋转不变性技术(Estimating Signal Parameter via Rotational Invariance Techniques, ESPRIT),或者是

多重信号分类(Multiple Signal Classification, MUSIC),因其高分辨率和较低的计算复杂度被广泛应用于各种信号探测设备。

然而在实际雷达应用中,面对非高斯噪声和杂波干扰,传统算法因依赖协方差矩阵的精确估计而性能严重衰减。而高阶累积量(Higher-Order Cumulants, HOC)不仅可以极大扩展阵列孔径,还对高斯噪声具有天然的抑制能力,这使得算法能有效提取非高斯信号的统计特征,在低信噪比(Signal-to-Noise Ratios, SNR)下仍能保持鲁棒性^[1]。

文献[2]采用互质L型阵列,构造四阶累积量并利用张量分解实现了闭式的二维DOA估计。该算法不仅解决了样本噪声扰动问题,还提高了阵列自由度,但其张量分解运算复杂度极高。文献[3]提出了一种基于四阶累积量的双网络多源DOA估计算法,可以在不需要精确阵列结构信息和无需阵列校准的情况下完成多源DOA估计,但因其天线分置并不适合小规模部署。文献[4]先对阵列接收信号特征分解,提取主信息分量,构建高斯窗修正的虚拟波束约束,再结合四阶累积量进行DOA估计,但其存在检测成功率不够稳定的问题。由以上研究可知,基于高阶累积量的DOA算法,虽可成倍扩展阵列孔径且抑制噪声干扰,但大多存在运算复杂度高的缺点。

此外,在实际复杂地形中因信号多径传播等干扰因素,会出现信号协方差秩亏损问题。而交替方向乘子法(Alternating Direction Multiplier Method, ADMM)作为一种分布式优化框架,特别适合求解高维、非光滑或带约束的DOA问题。该算法通过变量分裂将复杂问题拆解为多个子问题,并交替迭代求解,可在较少迭代次数内实现良好的收敛性^[5]。进一步灵活地嵌入Toeplitz结构约束、非凸惩罚函数约束,将显著提升模型的适应性,使得在剧烈噪声干扰、信号相干、阵元失效、数据缺失的情况下仍能利用现有数据实现DOA估计,确保了DOA估计的稳定性。

文献[6]提出一种基于虚拟阵列扩展的加权空间平滑算法,通过虚拟阵列扩展补偿子阵划分导致的孔径损失,构建基于子阵互协方差信息的加权矩阵,在低信噪比下有较高精度。文献[7]提

出一种基于二维重构的改进Toeplitz矩阵集重构法,通过将Toeplitz矩阵集与共轭转置矩阵相乘并求和,避免额外的去噪处理。该算法虽有较低复杂度,但面对多源相干信号性能较差。文献[8]将接收信号协方差矩阵分解为低秩无噪协方差矩阵和稀疏噪声协方差矩阵,构造凸优化问题求解有限采样下协方差矩阵估计误差问题。但其误差参数对性能影响显著,且其算法中的凸优化问题涉及高维矩阵分解,因此实时性受限。

本文结合降维高阶累积量与Toeplitz矩阵重构,通过理论分析和仿真实验,提出一种新型多源相干信号DOA估计算法。首先构建四阶累积量扩展阵列孔径,削弱高斯噪声干扰;之后提出一种科学高效的降维方法,既有更好的噪声鲁棒性,还有效降低了运算复杂度;然后提出一种自适应信噪比ADMM低秩Toeplitz矩阵重构法,将重构信号矩阵经MUSIC谱峰搜索得到DOA估计结果。不同场景下的仿真实验表明,本文算法在较低的计算复杂度下,在非高斯噪声环境中对多源相干信号亦有精确的估计结果。

1 阵列信号模型

如图1所示,一个配置了线性阵列(Uniform Linear Array, ULA)的雷达系统,由1个发射和 M 个接收阵元组成,阵列阵元间距为 $d = \lambda/2$, λ 为信号波长。假设 t 时刻存在 P 个远场窄带信号,分别位于方向 $\theta_1, \theta_2, \dots, \theta_P$ 。




图1 阵列信号模型

回波信号经匹配滤波后,接收数据可表示为

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \in \mathbb{C}^{M \times 1} \quad (1)$$

式中, $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_P] \in \mathbb{C}^{M \times P}$ 是联合导向矩阵,其中 $\mathbf{a}_p$ 是第 p 个目标的导向向量:

$$\mathbf{a}_p(\theta_p) = \left[1, e^{j\frac{2\pi d \sin \theta_p}{\lambda}}, \dots, e^{j\frac{2\pi(M-1)d \sin \theta_p}{\lambda}} \right]^T \quad (2)$$

而 $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_p(t)]^T \in \mathbb{C}^{P \times 1}$ 是匹配滤波后的信号矩阵。 $\mathbf{n}(t) \in \mathbb{C}^{M \times 1}$ 是加性噪声向量,其中包含高斯噪声、杂波干扰、脉冲噪声和相位噪声等多种分量。当接收信号包含 L 个快拍时,此时的观测数据矩阵 $\mathbf{X} \in \mathbb{C}^{M \times L}$ 可表示为

$$\mathbf{X} = [\mathbf{x}(t_1), \mathbf{x}(t_2), \dots, \mathbf{x}(t_L)] = \mathbf{A}\mathbf{S} + \mathbf{N} \quad (3)$$

式中, $\mathbf{S} = [\mathbf{s}(t_1), \mathbf{s}(t_2), \dots, \mathbf{s}(t_L)] \in \mathbb{C}^{P \times L}$, $\mathbf{N} = [\mathbf{n}(t_1), \mathbf{n}(t_2), \dots, \mathbf{n}(t_L)] \in \mathbb{C}^{M \times L}$ 。

2 算法原理

2.1 MUISC 算法

以图1阵列信号模型为例,对于式(3)的阵列接收信号,可得信号的理想协方差为

$$\mathbf{R}_{XX} = E[\mathbf{X}\mathbf{X}^H] = \mathbf{A}\mathbf{R}_S\mathbf{A}^H + \sigma^2\mathbf{I} \in \mathbb{C}^{M \times M} \quad (4)$$

式中, $\mathbf{R}_S = E[\mathbf{S}(t)\mathbf{S}^H(t)]$ 为信号协方差矩阵, $\sigma^2\mathbf{I}$ 为噪声协方差矩阵, σ^2 为噪声方差, $\mathbf{I}$ 为单位矩阵。显然协方差矩阵由信号 $\mathbf{S}(t)$ 与噪声 $\mathbf{N}(t)$ 两部分组成。此时信噪比估计公式为

$$\text{SNR} = 10 \cdot \lg \left(\frac{\|\mathbf{X}\|_F^2 - M L \sigma^2}{M L \sigma^2} \right) \quad (5)$$

式中, $\|\mathbf{X}\|_F$ 为 $\mathbf{X}$ 的F范数,即

$$\|\mathbf{X}\|_F = \sqrt{\sum_i \sum_j X_{i,j}^2} \quad (6)$$

实际应用中,由于采样数据有限长,我们通常使用观测数据样本的协方差进行DOA估计:

$$\hat{\mathbf{R}} = \frac{1}{L} \sum_{t=1}^L \mathbf{x}(t) \mathbf{x}^H(t) = \frac{1}{L} \mathbf{X}\mathbf{X}^H \quad (7)$$

定义MUSIC算法功率谱为

$$P_{\text{MUSIC}}(\theta) = \frac{1}{\mathbf{A}^H(\theta) \mathbf{U}_N \mathbf{U}_N^H \mathbf{A}(\theta)} \quad (8)$$

其前 P 个峰值即DOA角度 θ 。同时根据上述推导,MUSIC算法至多可估计 $M-1$ 个信源。

2.2 降维高阶累积量算法

对于零均值的平稳复随机过程 $\mathbf{x}$,其一种四阶累积量(Forth Order Cumulant, FOC)定义为

$$\begin{aligned} C_4(t_1, t_2, t_3, t_4) &= \text{cum}(t_1, t_2, t_3, t_4) = \\ &E[\mathbf{x}(t_1) \mathbf{x}(t_2) \mathbf{x}^*(t_3) \mathbf{x}^*(t_4)] - \\ &E[\mathbf{x}(t_1) \mathbf{x}^*(t_3)] E[\mathbf{x}(t_2) \mathbf{x}^*(t_4)] - \\ &E[\mathbf{x}(t_1) \mathbf{x}^*(t_4)] E[\mathbf{x}(t_2) \mathbf{x}^*(t_3)] - \\ &E[\mathbf{x}(t_1) \mathbf{x}(t_2)] E[\mathbf{x}^*(t_3) \mathbf{x}^*(t_4)] \quad (9) \end{aligned}$$

式中, $\text{cum}(\cdot)$ 表示变量的累积量, $(\cdot)^*$ 表示矩阵复共轭, $E[\mathbf{x}(t_1) \mathbf{x}(t_2) \mathbf{x}^*(t_3) \mathbf{x}^*(t_4)]$ 表示 $\mathbf{x}(t)$ 的四阶矩, $E[\mathbf{x}(t_i) \mathbf{x}(t_j)]$ 表示 $\mathbf{x}(t)$ 的二阶矩。

对于高斯随机过程 y ,其高阶矩可描述为

$$E(y^k) = \begin{cases} 1 \times 3 \times \dots \times (k-1) \sigma^2, & k = 2n \\ 0, & k = 2n+1 \end{cases} \quad (10)$$

显然,高斯随机变量的高阶累积量 ($k \geq 2$) 恒等于0,且其高阶矩只取决于二阶矩 σ^2 [9]。

由式(4)可知,协方差矩阵 $\mathbf{R}_{XX}$ 可分解为噪声和信号子空间协方差矩阵的组合。同理,四阶累积量可实现类似分解,根据式(9)的四阶累积量形式,此时令第 p 个目标的累积量矩阵为

$$\begin{aligned} \mathbf{C}_p &= E[(\mathbf{x} \otimes \mathbf{x}^*)(\mathbf{x} \otimes \mathbf{x}^*)^H] - \\ &E[\mathbf{x}\mathbf{x}^H] \otimes E[(\mathbf{x}\mathbf{x}^H)^*] \quad (11) \end{aligned}$$

再将其扩展至 L 个快拍的情况可得:

$$\begin{aligned} \mathbf{C}_p &= \frac{1}{L} (\mathbf{X}_p \odot \mathbf{X}_p^*) (\mathbf{X}_p \odot \mathbf{X}_p^*)^H - \\ &\frac{1}{L^2} (\mathbf{X}_p \mathbf{X}_p^*) \otimes (\mathbf{X}_p \mathbf{X}_p^*)^* \quad (12) \end{aligned}$$

$$\begin{aligned} \mathbf{C} &= \sum_{p=1}^P \mathbf{C}_p = (\mathbf{A} \odot \mathbf{A}^*) \begin{pmatrix} c_1 & & \\ & \ddots & \\ & & c_P \end{pmatrix} \\ &(\mathbf{A} \odot \mathbf{A}^*)^H = \mathbf{B} \mathbf{C}_S \mathbf{B}^H + \mathbf{C}_N \quad (13) \end{aligned}$$

$$c_p = \frac{1}{L} (\mathbf{s}_p \odot \mathbf{s}_p^*) (\mathbf{s}_p \odot \mathbf{s}_p^*)^H - \frac{1}{L^2} (\mathbf{s}_p \mathbf{s}_p^*) \otimes (\mathbf{s}_p \mathbf{s}_p^*)^* \quad (14)$$

$$\mathbf{C}_N = \frac{1}{L} (\mathbf{n}_p \odot \mathbf{n}_p^*) (\mathbf{n}_p \odot \mathbf{n}_p^*)^H - \frac{1}{L^2} (\mathbf{n}_p \mathbf{n}_p^*) \otimes (\mathbf{n}_p \mathbf{n}_p^*)^* \quad (15)$$

式中, $\mathbf{X}_p = \mathbf{a}_p \mathbf{s}_p + \mathbf{n}_p \in \mathbb{C}^{M \times L}$ 为第 p 个目标的观测数据矩阵, $\mathbf{s}_p = [s_p(1), s_p(2), \dots, s_p(L)] \in \mathbb{C}^{1 \times L}$ 和 $\mathbf{n}_p \in \mathbb{C}^{1 \times L}$ 分别为第 p 个目标的多快拍信号和噪声, $\mathbf{C}_S$ 和 $\mathbf{C}_N$ 分别为目标信号的四阶累积量; c_p 为按式

(13)分解后, C_s 的对角线元素, $\odot$ 表示 Khatri-Rao 积。其中:

$$B = A \odot A^* \in \mathbb{C}^{M^2 \times P} \quad (16)$$

显然, 对比原阵列, 四阶累积实现了孔径扩展。与2.1节 MUSIC算法类似, 定义空间谱:

$$P_{\text{FOC}}(\theta) = \frac{1}{B^H(\theta) U_N U_N^H B(\theta)} \quad (17)$$

对式(17)进行谱峰搜索, 即可得到 DOA 角度。但对于原信号模型中 M 个接收阵元, 可知累积量矩阵 C 共有 M^4 个元素。因此式(17)的计算过程复杂度极高。为降低复杂度, 文献[10]给出了式(18)所示的逐元素快速去冗余办法:

$$\bar{C}_4 = [(k_1 - 1)M + k_2, (k_3 - 1)M + k_4] \quad (18)$$

式(18)的解算过程, 如式(19)~(20)所示:

$$\left\{ \begin{aligned} R_{4(2M-1, M^2)}(i, :) &= \frac{1}{i} \sum_{j=1}^i C_{(M^2, M^2)}[(j-1)(M-1) + \\ &\quad i, :], i \leq M \\ R_{4(2M-1, M^2)}(2M-i, :) &= \frac{1}{i} \sum_{j=1}^i C_{(M^2, M^2)} \cdot \\ &\quad [M(M-j+1) - i + j, :], i < M \end{aligned} \right. \quad (19)$$

$$\left\{ \begin{aligned} R_{4(2M-1, 2M-1)}(:, i) &= \frac{1}{i} \sum_{j=1}^i C_{(2M-1, M^2)}[:, (j-1) \cdot \\ &\quad (M-1) + i], i \leq M \\ R_{4(2M-1, 2M-1)}(:, 2M-i) &= \frac{1}{i} \sum_{j=1}^i C_{(2M-1, M^2)} \cdot \\ &\quad [:, M(M-j+1) - i + j], i < M \end{aligned} \right. \quad (20)$$

式中, R_4 为降维矩阵。但上述降维过程运算繁琐, 且由式(10)可知高斯噪声的四阶累积量为0, 因此文献[10]中降维矩阵是在高斯噪声下推导得出, 未考虑实际工作情况中矩阵降维前后噪声与信号功率的一致性。因此本文对四阶累积量降维算法提出一种更为高效科学策略。

对于四阶累积量矩阵, 定义:

$$H = [H_0^T, H_1^T, \dots, H_{M-1}^T]^T \in \mathbb{C}^{M^2 \times (2M-1)} \quad (21)$$

式中, $H_m = [O_{M \times (M-m)}, I_M, O_{M \times (m-1)}]$, I_M 为 M 维单位矩阵, $O_{M \times (M-m)}$ 为 $M \times (M-m)$ 的零矩阵, $m = 1, 2, \dots, M-1$ 。此时导向矢量可写为

$$B = A(\theta) \odot A^*(\theta) = HF(\theta) \quad (22)$$

式中, $F(\theta) = [f(\theta_1), f(\theta_2), \dots, f(\theta_p)] \in \mathbb{C}^{(2M-1) \times P}$

为去冗余阵元后虚拟阵列的阵列流型矩阵, 其中 $f(\theta) = [e^{-j(M-1)\sin\theta}, e^{-j(M-2)\sin\theta}, \dots, e^{j(M-1)\sin\theta}]$ 。

考虑到降维变换前后信号及噪声功率的一致性, 定义降维变换矩阵:

$$T = (H^T H)^{-1} H^T \in \mathbb{C}^{(2M-1) \times M^2} \quad (23)$$

表1为本文降维法与文献[10]逐元素降维法复杂度对比。逐元素降维法对累积量矩阵的行列两个维度分别进行降维, 相比之下本文算法只计算一次降维变换矩阵, 显然有更低的运算复杂度。

表1 降维算法运算复杂度对比

算法	复杂度
本文恒功率降维法	$O[2(2M-1)^2 M]$
文献[10]逐元素降维法	$O[4(2M-1)^2 M]$

将式(23)代入式(13)得降维的四阶累积量:

$$C_{\text{RD}} = TCT^H \in \mathbb{C}^{(2M-1) \times (2M-1)} \quad (24)$$

此时累积量矩阵 C_{RD} 从 $M^2 \times M^2$ 降维至 $(2M-1) \times (2M-1)$ 。对 C_{RD} 特征分解, 取其 $2M-1-P$ 个小特征值对应的特征向量构造噪声子空间 U_N , 结合降维的导向矢量矩阵 $F(\theta)$, 定义降维累积量空间谱:

$$P_{\text{RD-FOC}}(\theta) = \frac{1}{F^H(\theta) U_N U_N^H F(\theta)} \quad (25)$$

对式(25)进行谱峰搜索, 即可得到 DOA 角度。表2为降维前后运算复杂度的对比, 可见降维后运算复杂度得到指数级的降低。

表2 降维前后运算复杂度对比

降维前后	复杂度
降维前	$O[(M^2)^3] + O[(P^2 M^4)^2] + O[2M^2 \log M]$
降维后	$O[(2M-1)^3] + O[(P^2 (2M-1)^2)^2] + O[(2M-1) \log(2M-1)]$

2.3 ADMM低秩Toeplitz矩阵重构算法

ADMM是一种用于求解带有约束的凸优化问题的迭代方法, 适用于式(26)的问题形式:

$$\min_{x, z} f(x) + g(z) \text{ s.t. } Ax + Bz = c \quad (26)$$

式中, x, z 为优化变量, f, g 为待优化凸函数。

它将问题拆分为若干个子问题, 分别求解, 使得最终解满足所有约束。其优点是可将复杂问

题分解为较简单的子问题,每个子问题都能有较为简单的更新公式^[11]。

在阵列信号处理中,我们通常会利用式(7)的多快拍数据计算样本协方差矩阵。对于均匀线阵,理想协方差矩阵应满足半正定性(所有特征值非负)和Toeplitz结构(沿对角线元素相同)。但因噪声干扰和信号相干,实际协方差矩阵不满足上述特性,因此需要进行矩阵重构,辅以Toeplitz约束,以解决信号矩阵的秩亏问题^[12]。

假设 $\mathbf{R}$ 为重构矩阵。其同时满足Toeplitz结构且与 $\hat{\mathbf{R}}$ 能量相近,考虑如下优化问题:

$$\min_{\mathbf{R}} \frac{1}{2} \|\mathbf{R} - \hat{\mathbf{R}}\|_{\text{F}}^2 + \lambda \|\mathbf{R}\|_{*}, \text{ s.t. } \mathbf{R} \in \mathcal{T} \cap \mathcal{S}^+ \quad (27)$$

式中, $\frac{1}{2} \|\mathbf{R} - \hat{\mathbf{R}}\|_{\text{F}}^2$ 为拟合项, $\|\mathbf{R} - \hat{\mathbf{R}}\|_{\text{F}}^2$ 以F范数衡量重构矩阵 $\mathbf{R}$ 与样本协方差 $\hat{\mathbf{R}}$ 的差异; $\lambda \|\mathbf{R}\|_{*}$ 为低秩正则项, $\|\mathbf{R}\|_{*}$ 为以核范数代替的凸松弛约束函数; λ 为正则化参数,用于平衡数据拟合项与低秩约束; $\mathcal{T}$ 表示所有Toeplitz矩阵的集合, $\mathcal{S}^+$ 表示所有半正定矩阵的集合。

在动态环境中,SNR变化会影响噪声功率和信号相干性,因此本文算法引入 λ 自适应调整机制以优化重构性能。根据式(5)得到SNR估计值后,对其进行指数衰减映射:

$$\lambda = \lambda_{\min} + (\lambda_{\max} - \lambda_{\min}) e^{-\alpha \cdot \text{SNR}} \quad (28)$$

式中, $\lambda_{\min}$ 和 $\lambda_{\max}$ 为算法给定的上下界, α 为衰减速率。即低信噪比时强化低秩约束,抑制噪声引起的矩阵秩升高;高信噪比保真数据拟合,避免过度约束导致信号失真。

采用ADMM求解上述优化问题,首先引入一个辅助变量 $\mathbf{Z}$,式(27)问题等价于

$$\begin{aligned} \min_{\mathbf{R}, \mathbf{Z}} \quad & \frac{1}{2} \|\mathbf{R} - \hat{\mathbf{R}}\|_{\text{F}}^2 + \lambda \|\mathbf{Z}\|_{*} \\ \text{s.t.} \quad & \mathbf{Z} = \mathbf{R} \in \mathcal{T} \cap \mathcal{S}^+ \end{aligned} \quad (29)$$

即将数据拟合项作用于 $\mathbf{R}$,低秩约束和结构约束作用于 $\mathbf{Z}$,再利用 $\mathbf{Z} = \mathbf{R}$ 将二者相关联。

根据式(29)构造增广拉格朗日函数:

$$\begin{aligned} \mathcal{L}(\mathbf{R}, \mathbf{Z}, \mathbf{Y}) = & \frac{1}{2} \|\mathbf{R} - \hat{\mathbf{R}}\|_{\text{F}}^2 + \lambda \|\mathbf{R}\|_{*} + \\ & \langle \mathbf{Y}, \mathbf{R} - \mathbf{Z} \rangle + \frac{\rho}{2} \|\mathbf{R} - \mathbf{Z}\|_{\text{F}}^2 \end{aligned} \quad (30)$$

式中, $\langle \mathbf{Y}, \mathbf{R} - \mathbf{Z} \rangle$ 为内积,目的为确保约束 $\mathbf{Z} = \mathbf{R}$ 被

满足,其中 $\mathbf{Y}$ 是拉格朗日乘子; $\frac{\rho}{2} \|\mathbf{R} - \mathbf{Z}\|_{\text{F}}^2$ 是额外的惩罚项, $\rho > 0$ 是惩罚参数。

ADMM迭代求解矩阵重构的更新步骤如下:

1)固定当前 $\mathbf{Z}^k$ 和 $\mathbf{Y}^k$,更新 $\mathbf{R}$,即求解

$$\begin{aligned} \mathbf{R}^{k+1} = & \arg \min_{\mathbf{R}} \frac{1}{2} \|\mathbf{R} - \hat{\mathbf{R}}\|_{\text{F}}^2 + \\ & \frac{\rho}{2} \|\mathbf{R} - \mathbf{Z}^k + \mathbf{Y}^k/\rho\|_{\text{F}}^2 \end{aligned} \quad (31)$$

式(31)为一个最小二乘问题,其梯度为

$$(\mathbf{R} - \hat{\mathbf{R}}) + \rho(\mathbf{Z}^k - \mathbf{Y}^k/\rho) = 0 \quad (32)$$

其闭式解为

$$\mathbf{R}^{k+1} = \frac{\hat{\mathbf{R}} + \rho(\mathbf{Z}^k - \mathbf{Y}^k/\rho)}{1 + \rho} \quad (33)$$

解为Toeplitz集合上的加权平均。

2)固定 $\mathbf{R}^{k+1}$ 和 $\mathbf{Y}^k$,更新 $\mathbf{Z}$

$$\mathbf{Z}^{k+1} = \arg \min_{\mathbf{Z} \in \mathcal{T} \cap \mathcal{S}^+} \lambda \|\mathbf{Z}\|_{*} + \frac{\rho}{2} \|\mathbf{Z} - \mathbf{U}\|_{\text{F}}^2 \quad (34)$$

式中, $\mathbf{U} = \mathbf{R}^{k+1} + \mathbf{Y}^k/\rho$,对 $\mathbf{U}$ 做奇异值阈值(Singular Value Threshold, SVT)操作,即先对 $\mathbf{U}$ 执行奇异值分解:

$$\mathbf{U} = \mathbf{U}_U \boldsymbol{\Sigma}_U \mathbf{V}_U^H \quad (35)$$

结合引入的动态调整 λ 的策略,再对得到的奇异值同步进行软阈值处理,将每个奇异值 σ_i 更新为

$$\tilde{\Sigma}_U = \text{diag}[\max(\sigma_i - \lambda^k/\rho, 0)] \quad (36)$$

由此重构得

$$\mathbf{Z}' = \mathbf{U}_U \tilde{\Sigma}_U \mathbf{V}_U^H \quad (37)$$

之后先对 $\mathbf{Z}'$ 取均值进行Toeplitz投影,再对该矩阵特征分解,投影到半正定集合。重复此步骤,直至收敛得到 $\mathbf{Z}^{k+1}$ 。


3)更新拉格朗日乘子 $\mathbf{Y}$

$$\mathbf{Y}^{k+1} = \mathbf{Y}^k + \rho(\mathbf{R}^{k+1} - \mathbf{Z}^{k+1}) \quad (38)$$


缩小 $\mathbf{R}$ 与 $\mathbf{Z}$ 差距,逼近 $\mathbf{Z} = \mathbf{R}$ 约束。

图2为矩阵重构前后的对比,由图可知重构矩阵与原矩阵的误差很小,既实现了矩阵的半正定性和Toeplitz性,还尽量保留了原矩阵信息。

表3展示了ADMM法Toeplitz重构和经典Toeplitz重构复杂度的对比,可见本算法主要复杂度由迭代次数 k 和信源数 P 决定,换言之ADMM带来的计算开销很小。



(a) 原矩阵元素分布



(b) 重构矩阵元素分布

图2 矩阵重构前后对比

表3 不同矩阵重构法复杂度对比

算法	复杂度
ADMM法Toeplitz矩阵重构	$O[kPM^2]$
经典Toeplitz矩阵重构	$O[M^2]$

综上,本文基于降维累积量和ADMM低秩重构的多源相干DOA估计算法如表4所示。

表4 降维累积量ADMM低秩Toeplitz矩阵重构算法

输入:观测数据矩阵 X ;

输出:DOA估计结果 θ ;

①计算观测数据矩阵 X 的四阶累积量 C_4 ,并得到虚拟阵列的导向矢量矩阵 B ;

②构造降维变换矩阵 H 和 T ,对导向矢量 B 和四阶累积量 C_4 进行降维变换,得到降维矩阵 C_{RD} 和降维导向矢量 F ;

③初始化 $R^0 = C_{RD}$, $Z^0 = C_{RD}$, $Y^0 = 0$;

for $k = 0, 1, 2, \dots$

$$R^{k+1} = [\hat{R} + \rho(Z^k - Y^k/\rho)] / (1 + \rho);$$

$$U = R^{k+1} + Y^k/\rho;$$

$$\tilde{\Sigma}_v = \text{diag}[\max(\sigma_i - \lambda/\rho, 0)], Z' = U \tilde{\Sigma}_v U^H;$$

Toeplitz投影和半正定投影迭代得 Z^{k+1} ;

$$Y^{k+1} = Y^k + \rho(R^{k+1} - Z^{k+1});$$

if $\|R^{k+1} - Z^{k+1}\|_F^2 < \varepsilon$ break

end

④对迭代矩阵 R 特征分解,取前 P 个大特征值对应特征向量构建噪声子空间 U_N ;

⑤使用MUSIC算法,利用降维导向矢量 F 和噪声子空间 U_N 谱峰搜索得到信源 θ 。

3 仿真与分析

本文对传统DOA算法在实际应用中的性能衰减做出了诸多改进。本节对算法进行仿真验证,设置不同的仿真场景,与同类算法进行横向对比,验证了本算法在复杂场景中优良的性能表现。

实验1 验证本文算法经过矩阵重构之后,对相干信号的估计表现。仿真参数如下:非高斯噪声条件、 $SNR = -10$ 、快拍数为100、发射和接收阵元分别为1和8、本文算法迭代1次、非高斯相干信号。仿真结果如图3和图4所示。




图3 矩阵重构前后估计性能对比




图4 矩阵重构前后RMSE对比

由图3可知,未经矩阵重构的算法面对相干信号会丢失目标,而经过重构的算法在低信噪比和少快拍下都保持了良好的性能。最后根据图4的均方根误差(Root Mean Square Error, RMSE)变化曲线可看出非高斯噪声和相干信号条件下经过矩阵重构算法的RMSE水平更低,消融实验结果说明了

矩阵重构的必要性。

实验2 验证算法在高斯噪声下,分别在不同信噪比时对相干信号的估计表现。仿真参数如下:高斯噪声条件、快拍数为100、发射和接收阵元分别为1和8、本文算法迭代1次、非高斯相干信源。仿真结果如图5和图6所示。




图5 高斯噪声下相干信号估计性能对比





图6 高斯噪声下相干信源不同信噪比RMSE

由图5(a)可知,在 $SNR=0$ 时,文献[14]算法与本文性能相近,而文献[13]算法会丢失目标。图5(b)当 $SNR=-10$ 时,前两者算法均有较大误差。且文献[13]算法因空间平滑存在孔径损失,因此在图5(c)中,信源数增加至8时,该算法无法运行。最后根据图6的RMSE变化曲线可看出高斯噪声条件下本文算法的RMSE水平更低,实验结果说明了本文算法解相干的有效性。

实验3 验证算法在高斯噪声下,分别在不同信噪比时对非相干信号的估计表现。仿真参数如下:高斯噪声条件、本文算法迭代1次、快拍数为100、发射阵元为1、接收阵元为8、8个非高斯非相干信源。仿真结果如图7和图8所示。

由图7(a)可知,在 $SNR=0$ 下文献[15]算法与本文算法性能相近。但在图7(b)中,随着信噪比持续降低,因波束指向性变差,表现逐渐弱于本算法。极端情况下,因其较高的旁瓣水平,可能会出现伪峰,造成严重的估计错误。对比图8中曲线可






图7 高斯噪声下非相干信号估计性能




图8 高斯噪声非相干信源不同信噪比 RMSE

看出,高斯噪声条件下,在信噪比变化区间,尤其是低信噪比段,相比其他算法,本算法的RMSE水平更低,实验结果说明了本文所提算法的稳定性。

实验4 验证算法在非高斯噪声的环境中在不同信噪比下的估计性能表现。仿真参数如下:非高斯噪声条件(50%高斯噪声,40%杂波干扰,10%脉冲噪声,10%脉冲噪声率、10%相位噪声率)、本文算法迭代次数为1、快拍数为100、发射阵元为1、接收阵元为8、8个非高斯非相干信源。仿真结果如图9至图12所示。

对比图9(a)和图9(b),非高斯噪声下文献[12]算法劣化严重,文献[9]算法受益于传播算子的特性,某些情况下相比之前有更好的性能,但低信噪比下会丢失目标。

由图10可知,非高斯噪声下文献[14]算法会出现极大误差,即便 $SNR = 0$ 时也会丢失目标。






图9 非高斯噪声下非相干信号估计性能

图10 非高斯噪声, $SNR = 0$, 相干信号估计性能

对比图11和图12可知,无论是否为高斯噪声或相干信号,本文算法的RMSE都更低,实验结果说明了本文所提算法具有较好的鲁棒性。

实验5 验证各算法在高斯噪声的环境中,分别对相干信号在不同快拍数下的估计性能。仿真参数如下:高斯噪声条件、本文算法迭代次数为




图11 非高斯噪声下相干信源不同信噪比RMSE





图12 非高斯噪声非相干信源不同信噪比RMSE

1、信噪比分别为-10和0、快拍数为100~1 000、发射阵元为1、接收阵元为8、信源为非高斯相干信号。仿真结果如图13所示。


根据图13(a)可知,各算法的误差都会随快拍数增加而减小,其中文献[14]算法在高信噪比和多快拍条件下与本文算法接近。但在图13(b)中低信噪比的条件下,本文算法在少快拍数下明显更具优势,随快拍数有更快的收敛趋势。究其原因,本算法得益于引入的ADMM法对多快拍数据的迭代处理,其估计结果的RMSE水平更低,实验结果对比说明了本文算法的高效性。

实验6 验证各算法在非高斯噪声的环境中分别对相干和非相干信号在不同快拍数下的估计性能。仿真参数如下:非高斯噪声条件(同实验4)、本文算法迭代次数为1、信噪比为0、快拍数为100~1 000、发射阵元为1、接收阵元为8。仿真结果如图14所示。

由图14可知,在非高斯噪声场景下,本文算法的凭借迭代矩阵重构,在1~200快拍区间有更好的




(a) SNR=0




(a) SNR=-10

图13 高斯噪声相干信源不同快拍数RMSE



(a) 非相干信源




(b) 相干信源

图14 非高斯噪声,不同快拍数RMSE


性能表现。实验结果表明本算法在更少快拍下有更低的初始RMSE水平,实验结果验证了本文算法的优越性。

实验7 验证本算法在高斯与非噪声的环境中,分别在不同迭代次数下的估计性能表现。仿真参数如下:信噪比分别为-10和0、本文算法迭代次数为1~100、快拍数为100、发射阵元为1、接收阵元为8、非高斯相干信源。仿真结果如图15所示。

由图15(a)可知,在低信噪比下,1~20次的迭代即可显著降低估计结果的RMSE;而在高信噪比的条件下,1~2次迭代即可得到理想效果。由图15(b)可知,相比高斯噪声的环境,非高斯噪声条件下虽然准确度有所降低,但是体现出与高斯噪声环境中相似的趋势。综上实验结果可知本算法大部分情况下只需1~10次的迭代即可得到优良性能,很好平衡了算法复杂度与精确度。



(a) 高斯噪声



(b) 非高斯噪声

图15 高斯与非噪声相干信源不同迭代次数RMSE

4 结束语

本文研究了非高斯噪声干扰下多源相干信号的DOA估计问题,提出了一种结合降维高阶累积量和自适应信噪比ADMM法低秩Toeplitz矩阵重构的算法。首先计算阵列接收数据的四阶累积量,以实现削减高斯噪声和扩展阵列孔径;之后提出一种高效科学的降维策略,不仅提高了在非高斯噪声环境下的稳定性,还有效降低了运算复杂度;之后通过ADMM法高效迭代,灵活嵌入自适应信噪比约束和低秩Toeplitz约束,得到重构矩阵;最后利用MUSIC进行谱峰搜索得到目标精确的估计值。算法不仅实现了孔径扩展,还可在不损失阵列孔径的前提下实现多源相干信号探测,即便在低信噪比和非高斯噪声干扰的条件下依然保持良好的估计性能,实验验证了本算法在复杂干扰下DOA估计有着更强鲁棒性。本研究提出的算法不仅为雷达的阵列信号处理提供了新的解决思路,还为非理想环境中DOA估计平衡性能与效率提供了创新性技术路径。

参考文献:

- [1] MASSOUD A, IQBAL U, NOURELDIN A. Warped Fourth Order Cumulant Beamforming for Estimating DOA from Non-Uniform Linear Arrays of DIFAR Sonobuoys [C]// 2024 6th International Conference on Communications, Signal Processing, and Their Applications, Istanbul, Turkey: IEEE, 2024: 10794275.
- [2] ZHENG Hang, ZHOU Chengwei, WANG Yong, et al. Sample Fourth-Order Cumulant Tensor Denoising for DOA Estimation with Coprime L-Shaped Array [C]// 2021 55th Asilomar Conference on Signals, Systems, and Computers, Pacific Grove, CA, USA: IEEE, 2021: 1668-1672.
- [3] ZHANG Chenhao, WANG Wenjie, HONG Xi, et al. A Fourth-Order Cumulant-Based Multi-Sources DOA Estimation in UAV Collaborative Systems [J]. IEEE Signal Processing Letters, 2024, 31: 251-255.
- [4] 徐峰, 杨小鹏, 赵毅. 基于快速张量分解的波束空间MIMO雷达二维DOA估计算法[J]. 信号处理, 2022, 38(1): 1-8.
- [5] 李荣禄, 汤建龙, 袁永强. 基于TOEPLITZ重构的压缩感知嵌套阵列DOA估计[J]. 雷达科学与技术, 2024, 22

- (3): 334-340.
- [6] 孙志国, 柏乔森, 白永珍, 等. 基于虚拟阵列扩展的改进加权空间平滑算法[J]. 系统工程与电子技术, 2023, 45(1): 250-256.
- [7] JIN Aisuo, ZHANG Fei. 2D DOA Estimation of Coherent Sources Based on Reconstruction of Toeplitz Matrix Sets [C]//2020 Chinese Automation Congress, Shanghai, China: IEEE, 2020: 508-513.
- [8] 王洪雁, 于若男. 基于稀疏和低秩恢复的稳健DOA估计方法[J]. 电子与信息学报, 2020, 42(3): 589-596.
- [9] 窦慧晶, 郭威, 谢东旭, 等. 基于四阶累积量的改进传播算子DOA估计算法[J]. 北京工业大学学报, 2024, 50(9): 1061-1068.
- [10] 刁鸣, 吴小强, 李晓刚. 基于四阶累积量的测向方法研究[J]. 系统工程与电子技术, 2008, 30(2): 226-228.
- [11] KLIQUI Y. Toeplitz-Hermitian ADMM-Net for DOA Estimation [PP/OL]. arXiv, 2025. <https://doi.org/10.48550/arXiv.2502.13896>.
- [12] WEN Kelei, TIAN Ye, QIN Yunbai, et al. Toeplitz Rectification Based DOA Estimation Under the Coexistence of Mutual Coupling and Nonuniform Noise [J]. AEU-International Journal of Electronics and Communications, 2023 (1): 154453.
- [13] TIAN Gege, ZHAO Chenglu, LI Jingxiao, et al. The DOA Estimation Method Based on Improved SSMUSIC Algorithm [C]//2022 3rd China International SAR Symposium, Shanghai, China: IEEE, 2022: 9971459.
- [14] 张豪, 甄冬, 刘英辉, 等. 采用四阶累积量多重矩阵重构的低信噪比相干声源波达方向估计[J]. 声学学报, 2023, 48(2): 337-346.
- [15] 刘甲磊, 马佳智, 施龙飞. 虚拟波束四阶累积量DOA估计方法[J]. 系统工程与电子技术, 2022, 44(7): 2134-2142.
- 作者简介:**
- 刘宁庄 男, 硕士, 副教授, 主要研究方向为FPGA设计及相关应用。
- 侯志凯(通信作者) 男, 硕士研究生, 主要研究方向为阵列信号处理。
- 符渭波 男, 博士, 高级工程师, 主要研究方向为阵列信号处理、MIMO雷达信号处理。
- 田海波 男, 博士, 教授, 主要研究方向为智能机器人设计与运动控制、智能轮式/履带式车辆的动力学研究与控制。
-
- (上接第21页)
- [10] 李洁玉, 丛潇雨, 郭山红, 等. 一种机载组网雷达协同目标检测算法[J]. 现代雷达, 2024, 46(2): 70-77.
- [11] 盛琥, 汪海兵. 基于BLUE的雷达/红外异步融合算法研究[J]. 雷达科学与技术, 2023, 21(5): 575-580.
- [12] 盛琥, 汪海兵, 曲成华, 等. 去相关无偏转换量测的解耦算法[J]. 探测与控制学报, 2024, 46(6): 86-91.
- [13] SHENG Hu, WANG Haibin, ZHANG Pengfei, et al. Decorrelated Unbiased CMKF Algorithm for Bi-Static Radar Target Tracking [C]//2024 7th World Symposium on Communication Engineering, Tokyo, Japan, 2024: 40-43.
- 作者简介:**
- 陈书恒 男, 硕士, 高级工程师, 主要研究方向为航空电子装备论证和使用验证研究。
- 朱倪瑶(通信作者) 女, 硕士, 工程师, 主要研究方向为态势感知和目标识别研究。
- 王海鹏 男, 博士, 正高级工程师, 主要研究方向为信息融合技术研究。
- 张鑫 男, 博士, 工程师, 主要研究方向为航空电子装备论证和使用验证研究。

融合海洋环境要素的多尺度海面电磁散射建模

邵学辉, 冯杨楠, 薛冰, 王伟, 刘鹰

(哈尔滨工程大学智能科学与工程学院, 黑龙江哈尔滨 150001)

摘要: 为解决经典双尺度模型忽略真实海洋环境要素、对截断波数敏感而导致海杂波仿真精度不足的问题, 本文提出一种融合真实海洋环境要素的多尺度电磁散射建模方法。该方法利用实测波高、波向与风场数据生成重力波, 并结合 Elfouhaily 海谱生成张力波, 按照斜率通过线性叠加法构建多尺度几何海面; 进而, 采用一种含自适应截断波数的积分方程-基尔霍夫近似混合方法 (Integral Equation Method-Kirchhoff Approximation, IEM-KA) 计算其电磁散射特性。将该方法在多波段、多海况及不同擦地角条件下, 以 NRL 模型、KaDPMod 模型及 Ka 波段实测数据作为基准, 与传统 JONSWAP-TSM 组合方法进行对比验证。结果表明, 与传统方法相比, 新方法在 1~6 级海况下的后向散射强度预测精度显著提升, 在不同雷达擦地角下均表现出良好适用性, 且模拟结果与实测数据高度吻合。本文所提方法有效克服了传统模型对海洋环境要素依赖不足的缺陷, 为获取高保真、全要素的海杂波模拟数据提供了可靠的技术途径。

关键词: 真实海洋环境要素; 几何海面; 电磁散射计算; 双尺度方法

中图分类号: TN011

文献标志码: A

文章编号: 1672-2337(2026)01-0042-10

引用格式: 邵学辉, 冯杨楠, 薛冰, 等. 融合海洋环境要素的多尺度海面电磁散射建模[J]. 雷达科学与技术, 2026, 24(1): 42-51.

SHAO Xuehui, FENG Yangnan, XUE Bing, et al. Multi-Scale Sea Surface Electromagnetic Scattering Modeling Integrating Marine Environmental Elements[J]. Radar Science and Technology, 2026, 24(1): 42-51.

Multi-Scale Sea Surface Electromagnetic Scattering Modeling Integrating Marine Environmental Elements

SHAO Xuehui, FENG Yangnan, XUE Bing, WANG Wei, LIU Ying

(College of Intelligent Systems Science and Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract: To address the problem that the classic two-scale method neglects real marine environmental parameters and is sensitive to the cutoff wavenumber, leading to insufficient accuracy in sea clutter simulation, a multi-scale electromagnetic scattering modeling method that incorporates real marine environmental parameters is proposed in this paper. The method utilizes the measured data of wave height, wave direction, and wind field to generate gravity waves and combines them with capillary waves generated from the Elfouhaily spectrum, constructing a multi-scale geometric sea surface via slope-based linear superposition method. Subsequently, the hybrid integral equation method-Kirchhoff approximation (IEM-KA) with adaptive cutoff wavenumber is employed to calculate its electromagnetic scattering characteristics. The proposed method is validated by comparing it with the traditional JONSWAP-TSM combined method, using the NRL model, the KaDPMod model, and measured Ka-band data as benchmarks under various bands, sea states, and grazing angles. Results demonstrate that, compared to the traditional method, the new approach significantly improves the prediction accuracy of backscattering strength under the sea states of 1~6, exhibits excellent applicability at different grazing angles, and its simulation results are in high agreement with the measured data. The proposed method effectively overcomes the deficiency of traditional models' insufficient reliance on marine environmental parameters, providing a reliable technical pathway for obtaining high-fidelity and full-factor sea clutter simulation data.

Key words: real marine environmental parameters; geometric sea surface; electromagnetic scattering calculation; two-scale method (TSM)

0 引言

目前针对海面几何建模的主流方法是基于随机海浪理论的海谱法^[1],海谱能够反映海浪的能量分布以及频率分布。经典的海谱有 PM 谱^[2]、Elfouhaily 谱^[3]等。然而这类风驱海谱主要依赖风速这一参数,存在缺乏对真实波浪要素的直接表征和建模能力的问题,而电磁波和海面的相互作用主要发生在海面的微观几何结构层面,其散射特性依赖于波浪表面局部形态的真实描述,所以需要引入以真实海洋环境要素为输入的海面建模框架。该框架利用线性叠加法,将基于真实海洋环境参数生成的重力波和张应力波按照斜率分布叠加生成多尺度海面。

在海面几何建模的基础上可以进行电磁散射建模。Wright^[4]结合基尔霍夫近似法(Kirchhoff Approximation, KA)以及微扰法(Small Perturbation Method, SPM)提出了双尺度方法(Two-Scale Method, TSM),西安电子科技大学张民^[5]等人提出了一种基于面元模型的 TSM,用于计算在大范围下二维含破碎波海面的电磁散射模型,然而以上方法存在 KA 和 SPM 的适用区域不能够完整覆盖整个海面粗糙度以及对截断波数敏感的问题。

为了解决传统电磁散射后向散射系数计算未全面考虑海洋环境要素的问题,本文提出了在基于真实海洋环境要素建模^[6]的几何海面条件下采用自适应截断波数的 IEM-KA(Integral Equation Method-Kirchhoff Approximation)方法^[7]进行海面电磁散射分析,该方法更贴近真实的测试结果,最后通过与 NRL、KaDPMOD 模型以及实测数据对比验证了其在不同频段、不同海况下的适用性。

1 基于真实海洋环境要素的海面几何建模

本节引入真实海洋环境要素对海面进行几何建模,采用风浪谱模拟海面小尺度张应力波,并采用基于真实海浪参数的 JONSWAP 海谱模拟大尺度重力波,解决了传统风驱海谱建模在电磁散射计算时缺乏风速以外的其他环境要素表征(如波高、波周期、波向等)问题。

利用线性叠加法将生成的张应力波按照重力波的斜率分布叠加上去,假设叠加后的海浪高度起伏为 $z, \vec{\rho}_e = (x_e, y_e)$ 为张应力波面元内微结构的位置坐标矢量, $\zeta(\vec{\rho}_e, t)$ 为基于风浪谱张应力波幅度值, $\eta(\vec{\rho}_0, t)$ 为本文于多尺度海洋环境要素重力波海面元中心高度起伏值, Z_x 和 Z_y 分别为重力波 x 和 y 方向斜率,从而叠加在重力波斜率为 Z_x 和 Z_y 的小面元上的毛细海浪起伏高度可表示为

$$z = \eta(\vec{\rho}_0, t) + \zeta(\vec{\rho}_e, t) + Z_x x_e + Z_y y_e \quad (1)$$

Elfouhaily 海谱对 PM、JONSWAP 以及 Philips 等海谱进行修正和结合,将海浪谱的有效性扩大到了开阔海域的大风区海面,该模型的波数能量谱形式可分解为两部分,定义如下:

$$S_E(k) = k^{-3} [B_l(k) + B_h(k)] \quad (2)$$

式中, l, h 分别代表低频、高频, k 是波数,而 $B_l(k)$ 和 $B_h(k)$ 代表低频和高频分别对应的曲率谱。

$$B_l(k) = \frac{1}{2} \alpha_p \frac{c_p}{c} F_p \quad (3)$$

式中, $\alpha_p = 0.006 \sqrt{\Omega}$, $\Omega = U_{10}/c_p$ 表示无量纲逆波龄, $c_p = c(k_p)$ 即波谱峰值时的相速度, $k_p = k_0 \Omega_c^2$, $k_0 = g/U_{10}^2$ 。 F_p 为长波作用函数,表达式为

$$F_p = L_{PM} J_p \exp[-\Omega(\sqrt{k/k_p} - 1)/\sqrt{10}] \quad (4)$$

注意,上式中, L_{PM}, J_p 是与 JONSWAP 谱相关的参量,即

$$L_{PM} = \exp[-1.25(k/k_p)^{-2}] \quad (5)$$

$$J_p = \gamma^\Gamma \quad (6)$$

与 JONSWAP 海浪谱不同的是, E 谱根据峰值逆波龄 Ω_c 的取值范围重新定义了式(6)的参数,即

$$\gamma = \begin{cases} 1.7, & \Omega_c \leq 1 \\ 1.7 + 6 \log(\Omega_c), & 1 < \Omega_c < 5 \\ 2.7 \Omega_c^{0.57}, & \Omega_c \geq 5 \end{cases} \quad (7)$$

$$\Gamma = \exp(-0.5((k/k_p)^{0.5} - 1)^2/\sigma^2) \quad (8)$$

$$\sigma = \begin{cases} 0.08(1 + 4\Omega_c^{-3}), & \Omega_c < 5 \\ 0.16, & \Omega_c \geq 5 \end{cases} \quad (9)$$

$$\Omega_c = 0.84 \tanh\left[\left(X/X_0\right)^{0.4}\right]^{-0.75} \quad (10)$$

$$X = gx/U_{10}^2, X_0 = 2.2 \times 10^4 \quad (11)$$

$B_h(k)$ 表示短波曲率谱,即

$$B_h(k) = 0.5 \alpha_m c_m F_m / c \quad (12)$$

$$\alpha_m = 10^{-2} \begin{cases} 1 + \ln(u_f/c_m), & u_f \geq c_m \\ 1 + 3 \ln(u_f/c_m), & u_f < c_m \end{cases} \quad (13)$$

式中,摩擦风速 u_f 的单位是 m/s, c_m 是取曲率谱重力-毛细波峰值 k_m 时的最小相速度,一般取 $k_m = (\rho_w g/T)^{0.5} = 370 \text{ rad/m}$, $c_m = (2g/k_m)^{0.5} = 0.23 \text{ m/s}$, F_m 为短波作用函数,表示为

$$F_m = \exp[-1.25(k/k_p)^{-2} \exp[-0.25(k/k_m - 1)^2]] \quad (14)$$

由于重力波的直接表现就是海浪的波浪方向、波周期以及波高,所以应当采用真实波浪参数对重力波海浪进行模拟,这里采用由日本 Goda 团队优化的 JONSWAP 海谱,该海谱已经成为工程应用中广受认可的标准形式,主要形式如下:

$$S_j(f) = \beta_j H_s^2 T_p^{-4} f^{-5} \exp(-A) \cdot \gamma \quad (15)$$

式中, $A = 1.25X^{-4}$, $X = T_p f$, $\gamma = \exp(-B)$, $B = (X - 1)^2 / 2\sigma^2$ 。

$$\beta_j = \frac{0.06238}{D \cdot E} \quad (16)$$

式中, $D = 0.230 + 0.036\gamma - 0.185(1.9 + \gamma)^{-1}$, $E = 1.094 - 0.01915 \ln \gamma$

$$T_p = \frac{T}{1 - 0.532(\gamma + 2.5)^{-0.569}} \quad (17)$$

式中, $S_j(f)$ 表征波浪能量频率分布特性, H_s 和 T_p 为波浪参数,其余计算基准沿袭经典 JONSWAP 模型的核心框架,且无量纲谱宽参数 σ 表达式为

$$\sigma = \begin{cases} 0.07, & f \leq f_p \\ 0.09, & f > f_p \end{cases} \quad (18)$$

对于方向谱的选用,采用的是 Longuet-Higgins 使用的单边余弦形式:

$$\Phi_{LH}(k, \varphi) = G(s) \cos^{2s}(0.5(\varphi - \varphi_w)) \quad (19)$$

$$s = 1 - \frac{1}{\ln 2} \ln \left[\frac{1 - \Delta(k)}{1 + \Delta(k)} \right] \quad (20)$$

$$G(s) = 1 / \int_{-\pi}^{\pi} \cos^{2s}(0.5\varphi) d\varphi \quad (21)$$

$$\Delta(k) = \tanh \left[0.25 \ln 2 + 4 \left(\frac{c}{c_p} \right) + 0.13 u_f \left(\frac{c_m}{c} \right)^{2.5} \left(\frac{c_m}{c} \right) \right] \quad (22)$$

式中, s 为控制传播的参数, φ_w 为风向。

本节构建了一种基于真实海洋环境要素的双尺度海面几何模型。该模型采用在基于真实海洋环境参数生成的重力波上叠加张力波的方法,实现了对海面多尺度特征的精细化描述:利用 Goda-JONSWAP 谱,通过有效波高、峰值周期的实测参数精确重现大尺度重力波的能量结构与形态;利

用 Elfouhaily 谱,通过风速参数模拟附着其上的小尺度张力波。最终,通过线性叠加法按照斜率将二者叠加。这种方法不仅克服了传统模型仅依赖风速的单一性,而且使得生成的几何海面在波高、周期、波向等关键要素上与真实海洋环境高度吻合,为后续高保真度的电磁散射计算和海洋遥感仿真提供了坚实的基础。

2 IEM-KA 电磁散射模型

在海洋遥感领域,雷达对海面进行成像的过程本质上是通过回波信号来估计在各个位置的分辨单元的后向散射强度,所以为了进行海面成像需要进一步对生成的多尺度海面进行电磁散射计算,计算出各个分辨单元的雷达散射截面(Radar Cross Section, RCS)。

传统的双尺度方法针对大尺度波的后向散射系数计算采取 KA 方法,小尺度波采取 SPM 方法,然而 KA-SPM 方法存在间隙区域的问题,并不能完整地覆盖海面粗糙度,为解决这一问题,本文用积分方程法取代 SPM 方法,即

$$\sigma_{pQ}^{\text{Improved-TSM}} = \sigma_{pQ}^{\text{KA-GO}}(\theta_i, \theta_s) + \langle \sigma_{pQ}^{\text{IEM}}(\theta_i, \theta_s) \rangle \quad (23)$$

式中, p 表示散射场的极化方式, Q 代表入射场的极化方式。符号 $\langle \cdot \rangle$ 代表在大尺度波所决定的海面斜率基础上,对小尺度波的散射贡献进行集合平均,可将式(23)重写为如下形式:

$$\sigma_{pQ}^{\text{Improved-TSM}} = \sigma_{pQ}^{\text{KA-GO}}(\theta_i, \theta_s) + \int_{-\infty}^{\infty} d z_y \int_{-\cot \theta_i}^{\infty} d z_x \sigma_{pQ}^{\text{IEM}}(\theta_i, \theta_s) \cdot [1 + (z_x \cos \varphi + z_y \sin \varphi) \tan \theta_i] P(z_x, z_y) \quad (24)$$

$$\sigma_{pQ}^{\text{KA-GO}}(\theta_i, \theta_s) = \frac{\pi k^2 q^2}{q_z^4} |U_{pQ}|^2 P(Z_x, Z_y) \quad (25)$$

式中, k 是入射波波数, θ_i 是入射角, θ_s 是散射角, φ 是方位角, q 是相位因子, $Z_x = -q_x/q_z$, $Z_y = -q_y/q_z$, U_{pQ} 表示极化系数, $P(Z_x, Z_y)$ 是大尺度的斜率概率密度函数。

$$\sigma_{pQ}^{\text{IEM}} = \sigma_{pQ}^k + \sigma_{pQ}^c = \frac{k^2}{4\pi} \exp(-2k^2 \sigma^2 \cos^2 \theta_i) \cdot \sum_{n=1}^{\infty} \frac{|I_{pQ}^n|^2}{n!} S^{(n)}(2k \sin \theta_i, 0) \quad (26)$$

式中,

$$I_{pQ}^n = (2k\sigma \cos \theta_i)^n f_{pQ} \exp(-k^2 \sigma^2 \cos^2 \theta_i) + (k\sigma \cos \theta_i)^n F_{pQ} \quad (27)$$

$$f_{vv} = 2R_{vv} / \cos \theta \quad (28)$$

$$f_{hh} = -2R_{hh} / \cos \theta \quad (29)$$

$$F_{vv} = \left(\frac{\sin^2 \theta_i}{\cos \theta_i} - \frac{sq}{\varepsilon_r} \right) T_v^2 - 2 \sin^2 \theta_i \left(\frac{1}{\cos \theta_i} - \frac{1}{sq} \right) \cdot T_v T_{vm} + \left[\frac{\sin^2 \theta_i}{\cos \theta_i} - \frac{\varepsilon_r (1 + \sin^2 \theta_i)}{sq} \right] T_{vm}^2 \quad (30)$$

$$F_{hh} = \left(\frac{\sin^2 \theta_i}{\cos \theta_i} - \frac{sq}{\varepsilon_r} \right) T_h^2 - 2 \sin^2 \theta_i \left(\frac{1}{\cos \theta_i} - \frac{1}{sq} \right) \cdot T_h T_{hm} + \left[\frac{\sin^2 \theta_i}{\cos \theta_i} - \frac{\mu_r (1 + \sin^2 \theta_i)}{sq} \right] T_{hm}^2 \quad (31)$$

其中 $S^{(n)}(q, 0)$ 为 n 阶的海面谱函数。

双尺度方法的计算结果依赖于截断波数的选取, 所以截断波数的选择非常重要, 传统方法选择的截断波数依赖于经验参数, 使得截断波数并没有直接和入射波频率以及海况等因素直接关联, 从而影响了计算结果的精确性, 为了解决这一问题, 本文引入了自适应的截断波数方法, 该方法考虑了不同的入射波频率以及风速条件, 从而优化了对大小尺度波的划分, 这种自适应的截断波数可以根据海面状态的动态变化动态调整参数, 避免了由于固定截断波数设定带来的误差, 通过这一改进, 提升了双尺度方法对海面电磁散射系数计算的准确性。

大量的实验和研究结果表明, 海洋表面的粗糙度主要受到海谱中毛细重力波和毛细张力波的影响, 可以通过以下关系式描述海面粗糙度:

$$\frac{U_{10}}{U_*} = \frac{1}{\kappa} \ln \left(\frac{10}{z_0} \right) \quad (32)$$

海面粗糙度为

$$z_0 = 10e^{-20\sqrt{5\kappa} U_{10}^{-1/4}} \quad (33)$$

式中, κ 代表 von Karman 常数, U_* 表示摩擦风速, 研究表明, 摩擦风速和海面上方 10 m 处风速具有如下关系:

$$U_*^2 = C_{10} U_{10}^2 \quad (34)$$

$$C_{10} = 0.5 U_{10}^{1/2} \times 10^{-3} \quad (35)$$

研究表明, 中等入射角条件下的后向散射主

要受到小尺度波造成的漫散射影响, 因为通常小尺度波集中在海谱的高频部分, 所以定义为

$$\sigma_{\text{capillary_wave}} = \sqrt{\int_{k_{\text{cut}}}^{\infty} S(K) dK} = \sqrt{\int_{k_{\text{cut}}}^{k_c = 8k_p = 8g/U_{10}^2} S(K) dK} \quad (36)$$

$$10e^{-20\sqrt{5\kappa} U_{10}^{-1/4}} = \sqrt{\int_{k_{\text{cut}}}^{\frac{8g}{U_{10}^2}} S(K) dK} \quad (37)$$

式中, σ 代表海面上小尺度波的均方根高度, $S(K)$ 代表海谱, k_{cut} 代表大小尺度波的截断波数, 由于真实海面受到海水粘性阻尼的影响, 海谱模型中毛细波部分在均方根斜率及其高阶导数上的贡献较为显著。因此, 在计算海谱时, 需要对空间波数的取值范围进行合理截断。其中, k_c 代表空间波数的上限, $k_c \geq 8k_p$, 而 k_p 为谱峰波数。根据公式(37), 可以针对不同的风速条件, 自适应地选择最优的截断波数, 从而优化大小尺度波的划分, 提高海面散射建模的精度。

3 几何海面仿真效果验证

本节对基于真实海洋环境元素生成的多尺度海面进行仿真, 分别在 1~6 级海况条件下进行仿真, 仿真条件如表 1 所示。

表 1 不同海况下的海洋参数

海况	波高/m	波周期/s	波向/(°)	风速/(m·s ⁻¹)	风向/(°)
1	0.3	3.4	42	3	153
2	0.9	3.9	146	5	106
3	1.3	5.4	92	7	51
4	2.0	6.4	85	10	128
5	3.0	6.7	54	12	42
6	5.0	6.8	126	15	45

仿真结果如图 1~3 所示。

图 1~3 中, 基于 Elfouhaily 谱生成的张力波的海面幅值明显小于重力波的海面幅值, 叠加了张力波之后的海面幅值和重力波海面幅值是相同的, 但是海面纹理比重力波海面纹理更加清晰, 细节部分也更加完善, 同时随着海况的增加, 重力波的作用更加明显, 这一现象也符合实际情况。




图1 1~6级海况重力波海面




图2 1~6级海况张力波海面




图3 1~6级海况二维几何海面

4 电磁散射特性分析仿真验证

本节在生成的几何海面的基础上,进一步进行电磁散射特性的分析仿真,仿真流程如图4所示。




图4 仿真计算流程图

4.1 不同海况下所提方法与 NRL 模型对比验证

本节采用改进的 IEM-KA 方法,计算基于真实海洋环境要素生成的多尺度几何海面在 10 GHz 与 15 GHz 频点、1~6 级海况条件下的后向散射系数。为验证所提方法的有效性,选取美国海军实验室提出的 NRL 模型作为基准测试标准。该模型通过对大量实测数据的拟合建立,在 500 MHz~35 GHz 频段及 1~6 级海况范围内具有较高的海杂波电磁散射建模精度。NRL 模型的建模计算公式为

$$\sigma_{H,V}^0 = c_1 + c_2 \log_{10}(\sin(\varphi)) + \frac{(27.5 + c_3 \varphi) \log_{10}(f)}{1 + 0.95\varphi} + c_4(1+s) \left(\frac{1}{(2 + 0.085\varphi + 0.033s)} \right) + c_5 \varphi^2 \quad (38)$$

NRL 模型以雷达入射角、频率、海况等级作为输入,有 5 个自由参数,分别与水平极化和垂直极化的实验结果相匹配。其中, φ 为入射角, s 为海况等级, f 为雷达频率,自由参数定义如表 2 所示^[8]。


表2 NRL 模型参数

极化方式	C_1	C_2	C_3	C_4	C_5
HH	-73.00	20.78	7.351 0	25.65	0.005 4
VV	-50.79	25.93	0.709 3	21.58	0.002 1


同时,采用传统固定截断波数的 TSM 方法(即 SPM-KA 方法)对基于 JONSWAP 海谱生成的几何海面进行后向散射系数计算,作为对比实验组。最终通过均方根误差(Root Mean Square Error, RMSE)定量评估本文方法的精度提升效果。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (39)$$


仿真结果如图 5 和表 3 所示。




(a) 10 GHz HH 极化



(b) 10 GHz VV 极化



(c) 15 GHz HH 极化



(d) 15 GHz VV 极化

图5 散射系数-海况变化曲线

表3 不同海况下与 NRL 模型 RMSE 对比 dB

方法	频点-极化			
	10 GHz-HH	10 GHz-VV	15 GHz-HH	15 GHz-VV
所提方法	4.645 0	4.888 6	4.425 6	4.669 5
JONSWAP+ 固定截断	5.012 4	8.479 1	6.839 9	5.953 1

仿真结果表明,所提方法在 10 GHz 与 15 GHz 频点下的 HH 和 VV 极化条件中均表现出更低的均方根误差,相比基于 JONSWAP 海谱与传统双尺度方法组合,显著提升了散射建模精度。

4.2 不同擦地角不同海况下所提方法与 KaDPMOD 模型对比验证

分别在 $20^\circ \sim 70^\circ$ 擦地角下针对生成的 1~6 级海况的多尺度海面选取 KaDPMOD^[9]模型作为测试标准验证所提方法的有效性,Yurovsky 等人^[10]提出 KaDPMOD 模型测试地点位于黑海岸研究平台,美国喷气推进实验室、马萨诸塞大学阿默斯特分校和伍兹霍尔海洋研究所通过 Air-Sea Interaction Tower(ASIT)联合进行了后续实验,对该模型进行了验证,并将相关测试数据开源。KaDPMOD 模型为


$$\log \sigma_o = A_0(\theta, U) + A_1(\theta, U) \cos \phi + A_2(\theta, U) \cos 2\phi \quad (40)$$

式中,


$$A_j = \sum_{m=0}^4 \sum_{k=0}^1 C_{mnk} \theta^m (\log U)^k \quad (41)$$

式中,系数 C_{mnk} 通过最小化最小二乘误差拟合得到, θ 为雷达入射角, U 为海表面 10 m 风速,注意,此处 log 是以自然对数为底进行计算。公式(40)中的对数尺度仅用于数据拟合,而所得经验拟合则转换回线性单位重新计算 RCS。


在 35 GHz 雷达频率下,仿真结果见图6和表4。




(a) 1 级海况




(b) 2 级海况




(c) 3 级海况



(d) 4 级海况



(e) 5级海况



(f) 6级海况

图6 VV极化散射系数-擦地角变化曲线

表4 不同海况不同擦地角与KaDPMOD模型RMSE对比

方法	1级 海况	2级 海况	3级 海况	4级 海况	5级 海况	6级 海况
所提方法/dB	2.191	4.447	2.604	1.723	1.704	2.402
JONSWAP+固定 截断/dB	6.876	7.423	5.329	5.284	5.081	5.520

在所有6个等级海况中,所提方法均能较好地拟合实际散射特性,且整体趋势与KaDPMOD模型基本一致, $RMSE$ 均在5 dB以内,进一步验证了所提方法在不同海况条件下的广泛适应性与稳健性。

4.3 不同擦地角下所提方法与实测数据对比验证

选取Polverari等人采用KaBODS L0雷达散射计于2019年10月至2020年1月测试获得的实测数据对所提方法进行验证,该数据于马萨诸塞州的玛莎葡萄园岛($41^{\circ}19.50'N$, $70^{\circ}34.0'W$)获得,水深15 m,雷达的入射角范围覆盖 $20^{\circ}\sim 83^{\circ}$ (入射余角为 $7^{\circ}\sim 70^{\circ}$),极化方式为VV极化。具体雷达参数

如表5所示。

表5 玛莎葡萄园岛海面散射实验雷达系统参数

参数	参数值
工作频段	Ka波段
射频频率	35.75 GHz
PRF	1 000 Hz
传输功率	9 dBm
天线增益	23.58 dB
距离分辨率	1.5 m
雷达带宽	100 MHz
3 dB水平波束宽度	10°
3 dB垂直波束宽度	10°
极化方式	VV
平台高度	13.1 m
仰角分辨能力	1.6~4.4 m

根据文献[10]中公开的实测数据集,本文选取

1~4级实测数据($D_1\sim D_4$):


1) 实测数据 D_1 : kabods_2019-10-30T23.L1.nc

2) 实测数据 D_2 : kabods_2019-10-30T15.L1.nc


3) 实测数据 D_3 : kabods_2019-10-21T15.L1.nc

4) 实测数据 D_4 : kabods_2019-11-02T05.L1.nc

仿真结果如图7和表6所示。



(a) 1级海况



(b) 2级海况




图7 VV极化散射系数-雷达擦地角变化曲线

表6 不同海况不同擦地角下与实测数据RMSE对比

方法	1级海况	2级海况	3级海况	4级海况
所提方法/dB	4.258 4	4.274 4	3.407 7	3.821 0
JONSWAP+固定截断/dB	6.879 5	6.725 3	4.203 6	5.566 3

各组实验中所提方法与实测数据的 $RMSE$ 均小于5 dB,这表明所提方法在建模精度上具备较高的可靠性和适用性,且在不同的观测角度条件下具有良好的稳定性与泛化能力。

本节将所提方法分别以NRL模型、KaDPMOD模型及Ka波段实测数据作为基准,与传统JONSWAP-TSM组合方法进行对比验证,所提方法与不同模型基准的 $RMSE$ 均小于5 dB,效果好于传统JONSWAP-TSM组合方法。

本节的仿真验证工作主要集中在1~6级海况,在此范围内,所提方法与基准模型及实测数据吻合良好。对于7级及以上的更高海况,海面上会出现更为剧烈的非线性现象,如波浪破碎、白帽覆盖和浪花飞溅等^[11]。我们当前采用的基于线性叠加法构建几何海面的模型,虽然融合了真实海洋环境要素,但可能无法完全捕捉这些强非线性动力

学过程所导致的复杂海面微观结构。因此,将模型外推至更高海况时,其预测精度可能会受到影响。未来的研究工作将考虑在现有模型基础上,引入破碎波等非线性海面特征的建模,以期拓展模型在高海况下的适用范围。

在雷达擦地角方面,本节的验证工作覆盖了低至 7° 的角度,并取得了较好的效果。然而,在极低擦地角(例如小于 5°)条件下,电磁波与海面的相互作用机制会变得更加复杂,此时阴影效应、多径散射和波导效应等现象将成为影响后向散射的主要因素^[12]。本文采用的IEM-KA混合方法在当前框架下未对这些效应进行建模。因此,在极低擦地角区域,模型的预测精度可能存在一定的局限性。

5 结束语

本文提出了一种基于真实海洋环境要素的多尺度海面建模与后向散射系数计算方法,并引入自适应截断波数的IEM-KA方法以提升散射强度计算精度。通过在10~15 GHz频率、1~6级海况条件下的仿真实验,所提方法在后向电磁散射强度预测方面与经典的NRL模型保持高度一致。在35 GHz, Ka波段, VV极化条件下,不同擦地角下与KaDPMOD模型比较结果表明,所提方法能够准确刻画海杂波的角度响应特性, $RMSE$ 始终控制在5 dB以内。进一步选取KaBODS实测数据对模型进行验证,各等级海况下的建模结果均表现出良好的拟合精度和趋势一致性。经过仿真实验验证本文所提方法在不同海况、不同雷达观测参数条件下具有良好的稳定性、精确性和泛化能力,能够有效弥补传统建模方法在实际环境适应性上的不足,为海杂波散射建模及遥感反演应用提供了可靠的理论与技术支撑。

传统的目标检测算法,特别是恒虚警率(CFAR)处理器,其设计和性能评估往往基于一个核心假设:背景杂波的统计特性是已知且稳定的^[13],例如可以被瑞利(Rayleigh)、韦布尔(Weibull)或K分布等数学模型良好描述。然而,真实海洋环境远比这些平稳、均匀的统计模型复杂^[14]。而本文提出的融合海洋环境要素的多尺度

海面电磁散射建模,通过模拟电磁波与基于真实海洋环境要素生成的多尺度海面的相互作用这一物理过程来生成后向散射系数,可以为CFAR算法的检测门限设置提供一个更为精准且贴近物理真实的参考基准。这意味着,算法的开发和验证不再仅仅依赖于简化的数学假设,而是可以利用与真实环境紧密关联的仿真数据进行训练和测试。

参考文献:

- [1] 宿德志,吴世永,刘亮,等.基于海浪谱建模的海面偏振仿真研究[J].激光与光电子学进展,2021,58(14):345-352.
- [2] PIERSON JR W J, MOSKOWITZ L. A Proposed Spectral form for Fully Developed Wind Seas Based on the Similarity Theory of S. A. Kitaigorodskii[J]. Journal of Geophysical Research, 1964, 69(24): 5181-5190.
- [3] ELFOUHAILY T, CHAPRON B, KATSAROS K, et al. A Unified Directional Spectrum for Long and Short Wind-Driven Waves [J]. Journal of Geophysical Research: Oceans, 1997, 102(C7): 15781-15796.
- [4] WRIGHT J. A New Model for Sea Clutter[J]. IEEE Transactions on Antennas and Propagation, 1968, 16(2): 217-223.
- [5] LI Jinxing, ZHANG Min, FAN Wenna, et al. Facet-Based Investigation on Microwave Backscattering from Sea Surface with Breaking Waves: Sea Spikes and SAR Imaging [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(4): 2313-2325.
- [6] 吴涛.不同海域多频段海杂波特性差异与主要影响因素分析[D].西安:西安电子科技大学,2020.
- [7] 李东芳.非线性海面的电磁散射特性研究[D].成都:电子科技大学,2021.
- [8] GREGERS-HANSEN V, MITAL R. An Empirical Sea Clutter Model for Low Grazing Angles [C]//2009 IEEE Radar Conference, Pasadena, CA, USA: IEEE, 2009: 61-65.
- [9] POLVERARI F, WINETEER A, RODRIGUEZ E, et al. A Ka-Band Wind Geophysical Model Function Using Doppler Scatterometer Measurements from the Air-Sea Interaction Tower Experiment[J]. Remote Sensing, 2022, 14(9): 14092067.
- [10] YUROVSKY Y Y, KUDRYAVTSEV V N, CHAPRON B, et al. Modulation of Ka-Band Doppler Radar Signals Backscattered from the Sea Surface [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(5): 2931-2948.
- [11] ZHANG Xiaojun, SHUI Penglang, WEN Hang, et al. Sea-Spike Discrimination in Maritime Radars Based on Polarimetric Doppler Offset Differences[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63(1): 1-15.
- [12] YE Jing, WAN Yong, FAN Chenqin, et al. An Improved Two-Scale Model for Sea Surface Scattering in the Transition Range of Incidence Angles[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 3192318.
- [13] ALVARADO M C L, GARCIA F D A, JIMENEZ L P J, et al. Performance Evaluation of SOCA-CFAR Detectors in Weibull-Distributed Clutter Environments[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 3152936.
- [14] DONG Yunlong, WEI Jifeng, DING Hao, et al. A Dynamic False Alarm Rate Control Method for Small Target Detection in Non-Stationary Sea Clutter [J]. Journal of Marine Science and Engineering, 2024, 12(10): 12101770.

作者简介:

邵学辉 男,博士研究生,主要研究方向为信号处理。

冯杨楠(通信作者) 女,硕士研究生,主要研究方向为信号处理。

薛冰 男,硕士,副教授,主要研究方向为雷达信号处理。

王伟 男,博士,教授,主要研究方向为雷达信号处理。

刘鹰 男,博士,副研究员,主要研究方向为目标检测。

一种基于判别投影特征提取的杂波点迹滤除方法

汪 晋^{1,2}, 苏洪涛¹, 汪圣利², 田 强²

(1. 西安电子科技大学雷达信号处理全国重点实验室, 陕西西安 710071;
2. 南京电子技术研究所, 江苏南京 210039)

摘要: 在复杂环境下雷达面临大量杂波点迹,严重影响雷达对目标的有效跟踪。而杂波点迹滤除技术可有效抑制杂波引起的虚假点迹,减小系统处理负担,提升目标跟踪效能。用于雷达点迹过滤的特征越丰富,点迹分类判别的正确率越高,点迹过滤性能越好,因此,如何提取有效的特征是雷达杂波点迹过滤面临的一个重要问题。传统基于正则化最小二乘的特征提取算法在构造代价函数时忽略了投影空间中样本的类间重构关系和类内聚集性,导致降维后特征损失,不利于点迹属性的正确判别。为此,本文提出了一种基于正则化最小二乘加权判别投影的特征提取算法。该方法在重构样本时利用类间表示系数,实现重构误差的最小化;在构造代价函数时利用样本的表示系数生成类内加权矩阵,提升同类样本的紧致性,使降维后样本保留更多有效特征。为验证本文所提方法的通用性和有效性,我们采用公开人脸数据集和雷达实测数据分别进行了验证。在公开人脸数据集上的实验结果表明,所提方法的分类正确率至少提升4%,雷达实测数据处理结果表明,本文所提方法对杂波点迹抑制率达90%以上,同时目标点迹损失率保持在1%以下。

关键词: 点迹滤除; 特征提取; 维数简约; 判别投影

中图分类号: TN953

文献标志码: A

文章编号: 1672-2337(2026)01-0052-10

引用格式: 汪晋, 苏洪涛, 汪圣利, 等. 一种基于判别投影特征提取的杂波点迹滤除方法[J]. 雷达科学与技术, 2026, 24(1): 52-61.

WANG Jin, SU Hongtao, WANG Shengli, et al. A Feature Extraction Method Based on Discriminant Projections for Clutter Plot Filtering[J]. Radar Science and Technology, 2026, 24(1): 52-61.

A Feature Extraction Method Based on Discriminant Projections for Clutter Plot Filtering

WANG Jin^{1,2}, SU Hongtao¹, WANG Shengli², TIAN Qiang²

(1. National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China;
2. Nanjing Research Institute of Electronics Technology, Nanjing 210039, China)

Abstract: In complex environments, radars face a large number of clutter plots, which severely affect the effective tracking of targets. The clutter plot filtering technology can effectively suppress the false plots caused by clutter, reduce the system processing burden, and improve the target tracking performance. The richer the features used for radar plot filtering, the higher the accuracy of plot classification and discrimination, and the better the plot filtering performance. Therefore, how to extract effective features is an important issue for radar clutter plot filtering. The traditional feature extraction algorithm based on regularized least squares ignores the inter-class reconstruction relationship and intra-class clustering characteristics of samples in the projection space when constructing the cost function, resulting in feature loss after dimensionality reduction. To address this issue, this paper proposes a feature extraction algorithm based on regularized least squares weighted discriminant projection. The proposed method utilizes inter-class representation coefficients to reconstruct samples, thereby minimizing the reconstruction error. Furthermore, when constructing the cost function, the representation coefficients of the samples are used to generate an intra-class weighting matrix, which improves the compactness of similar samples, and preserves more effective features after dimensionality reduction. To verify the universality and effectiveness of the proposed method, a public facial dataset and radar measured data are used to conduct validation respectively. Experimental results on the public facial dataset show that the proposed method achieves at least 4% improvement in recognition accuracy. Processing results of the radar measured data demonstrate that the proposed

收稿日期: 2025-09-14; 修回日期: 2025-11-21

基金项目: 国家自然科学基金(62201418, 62192714)

method achieves a clutter plot suppression rate of over 90%, while the target plot loss rate remains below 1%.

Key words: plot filtering; feature extraction; dimensionality reduction; discriminant projections

0 引言

当雷达系统面临复杂的地理环境时,经过目标检测环节后不可避免会产生大量的杂波点迹,需要在航迹处理之前,根据点迹的特性进行预处理,剔除虚假杂波点迹,保留真实目标点迹,减轻航迹处理系统的压力,提升目标跟踪质量。一种有效的方法是根据点迹的特征进行分类,区分出真实目标点迹和杂波虚假点迹,从而将虚假点迹剔除问题转换为真假点迹的分类问题。近年来,基于K近邻、支持向量机、神经网络等机器学习方法已被应用于点迹分类与杂波点迹滤除^[1-3]。

在解决分类或识别问题时,通常先通过预处理提取有效特征,再利用分类器进行分类或识别^[4-7]。在点迹过滤方法中,预处理环节提取的特征越丰富,点迹分类的正确率越高,点迹滤除效果越好,但丰富的特征包含较多的数据维数,直接进行处理会引起维数灾难问题。考虑到目标或杂波点迹的信号级原始数据虽然数据维数较多,但具有稀疏结构,这意味着该高维数据可以投影到低维空间而不会丢失重要信息。因此,在保留有效特征的前提下,尽可能将信号从高维空间降低到低维空间,是提升特征提取效率的重要技术途径^[8-12]。

基于降维思想的典型特征提取方法如主成分分析法(PCA)^[13]、线性判别分析法(LDA)^[14]及其差分形式的最大边缘准则(Maximum Margin Criterion, MMC)算法^[15]等。该类线性子空间方法以其简单、高效和易于实现的特点得到了广泛应用。然而,该类方法只考虑了数据的全局结构信息,描述数据的非线性流形结构或局部线性结构的能力不足,在处理高度非线性数据时存在一定的局限性。高维数据通常具有低维的流形结构或者局部线性结构,而流形学习方法可高效提取高维数据中潜在的低维流形结构,近年来基于流形学习的降维算法受到广泛关注。例如局部线性判别嵌入(Locally Linear Discriminant Embedding, LLDE)算法^[16]通过保持降维前后样本间的局部结构信息,提升了

分类能力。在文献[16]的基础上,文献[17]利用样本类型的先验信息,提出了局部保持判别投影(Locality Preserving Discriminant Projections, LPDP)算法,进一步提升了算法的可视化性能。文献[18]中提出了一种图嵌入(Graph Embedding, GE)框架,对现行的流形学习算法进行了统一,并进一步提出了边缘Fisher分析(Marginal Fisher Analysis, MFA)降维算法,其性能优于线性子空间类方法。这类图嵌入类方法的不同之处主要体现在图的构造方式的差异。最常见的方法是根据预设的邻近参数,利用样本的K近邻获取样本的加权图。然而由于不同的样本具有不同的局部结构,采用统一、固定的邻近参数必然会带来性能的损失。实际应用中,能够准确描述所有样本局部结构特征最优邻近参数往往难以获得。

稀疏表示(Sparse Representation, SR)和协同表示(Collaborative Representation, CR)是两种有效的特征提取方法^[19-21]。二者都采用正则化最小二乘方法实现对样本的表示学习,并利用表示系数自适应提取数据的局部结构特征,实现样本数据的有效分类。文献[22]结合SR提出了一种判别稀疏近邻保持嵌入算法,该算法利用稀疏表示提取样本的局部特征,并保持样本降维前后的稀疏重构关系,取得了较好的识别性能。文献[23]基于CR提出了协同表示投影(Collaborative Representation based Projection, CRP)算法,该算法忽略了样本的类别信息,导致识别性能有限。文献[24]在CRP的基础上提出协同表示重构投影(Collaborative Representation Reconstruction based Projection, CRRP)算法,大幅提高了算法的性能。文献[25]提出了正则化最小二乘判别投影(Regularized Least Square based Discriminative Projections, RLSDP)算法,该算法通过最小化样本的重构误差来保持样本间的重构关系,同时最大化类间散度信息增加不同类样本之间的距离,从而提升了算法的分辨能力,但RLSDP算法存在三个方面的问题:第一,在样本重构过程中,忽略了类别间的重构关系,造成类别间数据结构信息的损失,当不同

类别样本间的相似性较大时,会引起较大的重构误差;第二,代价函数中未考虑对每一个类别中所有样本之间距离的最小化,导致投影空间中类内样本紧致性不足,造成判别性能损失;第三,保持了投影前后协同表示关系的一致性,忽略了对局部相似结构信息的保持,造成算法的鲁棒性不足。三个方面问题导致 RLSDP 对某些数据判别能力不足。

为此本文提出了一种正则化最小二乘加权判别投影 (Regularized Least Squares Weighted Discriminant Projections, RLSWDP) 的点迹特征提取算法。该算法为了实现重构误差最小化,采用高维空间中所有样本的协同表示系数对每个样本进行重构。更重要的是,该算法利用表示系数构造加权矩阵,一方面可维持样本在投影前后类内局部相似结构信息的一致性,另一方面通过最小化同类样本之间的距离,提升投影空间中同类样本的聚集性。最后为了提升算法在小样本情况下的稳定性,利用 MMC 思想构造代价函数,同时实现类间散度信息最大化和类内样本距离的最小化。算法利用特征值分解的方法求解代价函数,获得最优投影矩阵的解析解。在公开的 YALE 人脸数据集上的实验结果表明,本文提出的特征提取方法可以取得比其他方法更好的性能,特别是在训练样本比较少和特征维数比较低时,文中所提算法更具有明显的优势。在雷达实测数据上的验证结果表明,基于本文提出的特征提取算法对杂波点迹实现 90% 以上的滤除率,同时目标点迹损失率保持在 1% 以下。

1 基于特征提取的点迹滤除方法

1.1 样本数据与处理流程

杂波点迹滤除的效果依赖于点迹分类的正确率,而分类器是解决分类问题最基础、应用最广泛的模型之一。分类器具有不过分依赖专家经验和人工设定的硬性规则,尽量“让数据自己说话”的特点,其层次化的结构使得算法能够从数据中学习得到抽象的特征,从而有利于发现数据本身的内在关系,并最终提升分类性能,常见的分类器算法有决策树、随机森林、支持向量机、朴素贝叶斯

和神经网络等。分类器的性能高度依赖于输入数据的质量,如果训练数据的有效特征缺失或者无效特征过多,训练出的分类器性能会大打折扣,因此,保持数据特征的丰富性,往往比选择分类器更重要。

为了保留数据最原始的特征,基于特征提取的杂波点迹过滤方法以点迹的信号级原始数据为输入,由于一个点迹可能扩展到相邻的多个波束,且每个波束内的信号级原始数据包含距离和多普勒两维信息,因此一个点迹的完整的信号级原始数据包含相邻每个波束的距离和多普勒信息。该信息组成的输入向量维数较大,将其直接作为分类器的输入,会消耗较多的处理资源。考虑到目标或者杂波的信号级原始数据具有稀疏结构,这意味着该高维数据可以投影到低维空间而不会丢失重要信息,因此可以先对原始数据进行特征提取,在保留有效特征的前提下,将信号从高维空间降低到低维空间,再输入到分类器进行点迹分类。

根据上述分析,基于特征提取的杂波点迹滤除方法首先提取点迹所在距离单元前后的距离单元和多普勒单元二维信息,考虑到雷达回波信号可能会扩展到相邻波束,因此以点迹所在波束为中心,按方位和俯仰维提取出相邻波束的数据,形成待处理的高维样本数据。再通过基于判别投影的特征提取方法,对数据进行降维的同时保留更多的有效特征,最后输入到点迹分类器中进行处理,根据分类结果保留真实目标点迹,剔除虚假杂波点迹,实现杂波点迹滤除。其处理流程如图 1 所示。

每个波束内的数据为 $N_r \times N_d$ 的距离-多普勒二维数据,其中 N_r 为奇数,代表距离维上提取的距离单元的窗长度,点迹最强幅度位于第 $(N_r + 1)/2$ 个距离单元上, N_d 为多普勒通道数。以点迹所在波束为中心,分别在方位维提取 N_{azi} 个波束数据,在俯仰维提取 N_{ele} 个波束数据,最终一个点迹的信号级原始距离-多普勒数据是一个 $N_r \times N_d \times N_{azi} \times N_{ele}$ 大小的数据。对该数据进行重组,形成 $N_x \times 1$ 维的数据样本 x_i , 其中 $N_x = N_r \times N_{azi} \times N_d \times N_{ele}$ 。对该数据先进行特征提取,提取后的数据样本为 y_i , 再经过分类器后得出二元分类(杂波或目标)结果。




图1 基于特征提取的点迹滤除处理流程

1.2 基于判别投影的特征提取方法

假设一个包含 C 类的样本集合定义为 $X = \{\mathbf{x}_i \in \mathbb{R}^m, i = 1, 2, \dots, n\}$, 其中 $\mathbf{x}_i$ 表示第 i 个样本, 且 $n = \sum_{c=1}^C n_c$ 表示样本的数目, n_c 表示第 c 类样本的数目。先对正则化最小二乘法算法进行介绍, 并给出其 L_2 范数形式下的解析解, 基于此进一步说明 RLSDP 算法。假设任一样本 $\mathbf{x}_i$ 可以用除其本身的其他样本 $X = [\mathbf{x}_1, \dots, \mathbf{x}_{i-1}, 0, \mathbf{x}_{i+1}, \dots, \mathbf{x}_n]$ 表示, 其表示系数可以通过求解以下正则化最小二乘优化问题获得:

$$\min_{\mathbf{r}_i} \|\mathbf{x}_i - X\mathbf{r}_i\|_2^2 + \lambda \|\mathbf{r}_i\|_q \quad (1)$$

式中: $\mathbf{r}_i \in \mathbb{R}^n$ 为表示系数; $\lambda > 0$ 是正则化参数, 用于控制表示误差; q 为正则项的范数, 用于控制解的稀疏性。

SR 和 CR 都可以用式(1)来表示。当 $q = 1$ 时, 式(1)为 SR 方法; 当 $q = 2$ 时, 式(1)为 CR 方法。相对于 SR 方法, CR 方法具有解析解, 计算效率更高。RLSDP 是基于 CR 的方法。下面针对 $q = 2$ 的情况, 对式(1)进行求解。

将式(1)写成:

$$\min_{\mathbf{r}_i} \|\mathbf{x}_i - X\mathbf{r}_i\|_2^2 + \lambda \|\mathbf{r}_i\|_2^2, \text{ s.t. } \mathbf{e}_i^T \mathbf{r}_i = 0 \quad (2)$$

式中, 约束条件中的向量 $\mathbf{e}_i = [0, \dots, 0_{i-1}, 1, 0_{i+1}, \dots, 0_n]^T$, 其目的是为了将 $\mathbf{x}_i$ 从 X 中移除, 即让表示系数 $r_{ii} = 0$ 。

利用拉格朗日乘子法, 根据式(2)可构造拉格朗日函数

$$f(\mathbf{r}_i, \eta) = \|\mathbf{x}_i - X\mathbf{r}_i\|_2^2 + \lambda \|\mathbf{r}_i\|_2^2 + \eta \mathbf{e}_i^T \mathbf{r}_i \quad (3)$$

式中: η 为拉格朗日乘子。将式(3)对 $\mathbf{r}_i$ 求导, 并令导数等于 0, 可解得

$$\mathbf{r}_i = (X^T X + \lambda I)^{-1} \left(X^T \mathbf{x}_i - \frac{\eta}{2} \mathbf{e}_i \right) \quad (4)$$

式中, $I \in \mathbb{R}^{n \times n}$ 是一个单位矩阵。将式(4)代入式(2)的约束条件中, 解得

$$\eta = \frac{2\mathbf{e}_i^T (X^T X + \lambda I)^{-1} X^T \mathbf{x}_i}{\mathbf{e}_i^T (X^T X + \lambda I)^{-1} \mathbf{e}_i} \quad (5)$$

将式(5)代入式(4), 可得表示系数 $\mathbf{r}_i$ 的表达式为

$$\mathbf{r}_i = Q \left(X\mathbf{x}_i - \frac{\mathbf{e}_i^T Q X \mathbf{x}_i}{\mathbf{e}_i^T Q \mathbf{e}_i} \mathbf{e}_i \right) \quad (6)$$

式中, $Q = (X^T X + \lambda I)^{-1}$ 。

RLSDP 在获得每个样本的协同表示系数的基础上, 通过保持同类样本之间的重构关系, 同时最大化不同样本之间的可分离距离, 构造两个代价函数:

$$\min_P \sum_{i=1}^n \left\| P^T \mathbf{x}_i - \sum_{j=1}^n r_{ij}^+ P^T \mathbf{x}_j \right\|_2^2 \quad (7)$$

$$\min_P \sum_{i,j=1}^n \left\| P^T \mathbf{x}_i - P^T \mathbf{x}_j \right\|_2^2 W_{ij}^{(b)} \quad (8)$$

其中, r_{ij}^+ 和 $W_{ij}^{(b)}$ 的定义为

$$r_{ij}^+ = \begin{cases} r_{ij}, & \text{如果 } \mathbf{x}_i \text{ 和 } \mathbf{x}_j \text{ 属于同一类} \\ 0, & \text{其他} \end{cases} \quad (9)$$

$$W_{ij}^{(b)} = \begin{cases} 1/n - 1/n_c, & \text{如果 } \mathbf{x}_i \text{ 和 } \mathbf{x}_j \text{ 同属第 } c \text{ 类} \\ 1/n, & \text{其他} \end{cases} \quad (10)$$

根据式(7)和式(8), RLSDP 的代价函数定义为

$$\max_P \frac{\text{tr}(P^T X S_b X^T P)}{\text{tr}(P^T X (I - R^+ - (R^+)^T + R^+ (R^+)^T) X^T P)} \quad (11)$$

式中, $\text{tr}(\cdot)$ 表示矩阵的迹运算, $S_b = D^{(b)} - W^{(b)}$ 表示类间散度矩阵, $D^{(b)}$ 表示一个对角矩阵且其对角元素为 $D_{ii}^{(b)} = \sum_{j=1}^n W_{ij}^{(b)}$ 。求解式(11)等效于求解 $S_b X^T P = \gamma (I - R^+ - (R^+)^T + R^+ (R^+)^T) X^T P$ 的最大广义特征值问题, 其中 γ 和 P 分别是一组的最大特征值和特征向量, 选取最大的 d 个特征向量, 即可组成 d 维最优投影矩阵。

2 基于正则化最小二乘加权判别投影的特征提取方法

通过深入分析RLSDP的代价函数可以看出,RLSDP主要利用式(7)通过在投影空间下最小化每个样本 $\mathbf{x}_i$ 与其重构样本 $\sum_{j=1}^n r_{ij}^+ \mathbf{x}_j$ 的误差,保持投影前后样本的重构关系来提高分类性能。然而式(7)主要存在三个问题:第一,式(7)中只利用同类样本的表示系数 $\mathbf{r}_i^+ = [r_{i1}^+, \dots, r_{in}^+]^T$ 来重构 $\mathbf{x}_i$,忽略了不同类别间的表示关系,在RLSDP的表示误差 $\|\mathbf{x}_i - \mathbf{X}\mathbf{r}_i\|_2$ 比较小时,会产生较大的重构误差 $\|\mathbf{x}_i - \sum_{j=1}^n r_{ij}^+ \mathbf{x}_j\|_2$ 。这意味着,RLSDP并不能很好地保持样本间的重构关系。第二,式(7)中通过最小化每个样本与重构形式之间的距离,获得较小的单个样本的重构误差,但无法实现类内样本之间距离的最小化,导致投影空间中类内样本紧致性不足,判别能力下降。第三,表示系数在一定程度上反映了样本之间的局部相似度结构,例如表示系数数值越大代表两个样本距离越近,反之则代表距离越远,在降维前后保持样本的局部结构关系有利于提升识别的稳定性,而RLSDP算法忽略了局部结构关系。

为了解决RLSDP算法中存在的上述三个问题,提出RLSWDP算法。

2.1 算法推导

假设样本 $\mathbf{x}_i$ 的重构样本为 $\hat{\mathbf{x}}_i = \mathbf{X}\mathbf{r}_i$,将式(7)改为如下形式:

$$\min_P \sum_{i,j=1}^n \|\mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \hat{\mathbf{x}}_j\| \hat{\mathbf{W}}_{ij}^{(w)} \quad (12)$$

式中, $\hat{\mathbf{W}}_{ij}^{(w)}$ 是样本 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 的加权矩阵,用来表示类内数据的相关性结构信息,定义为

$$\hat{\mathbf{W}}_{ij}^{(w)} = \begin{cases} 1, & \text{如果}\mathbf{x}_i\text{和}\mathbf{x}_j\text{属于同一类且}i=j \\ \alpha r_{ij}, & \text{如果}\mathbf{x}_i\text{和}\mathbf{x}_j\text{属于同一类且}i \neq j \\ 0, & \text{其他} \end{cases} \quad (13)$$

式中, $\hat{\mathbf{W}}_{ij}^{(w)}$ 用于约束同类别样本。根据 $\hat{\mathbf{W}}_{ij}^{(w)}$ 的定义,最小化式(12)不但可以实现样本 $\mathbf{x}_i$ 与其重构样本之间的误差的最小化,而且可以最小化样本 $\mathbf{x}_i$ 与其同类样本之间的距离,这有利于提高类内紧致

性。此外,注意到式(13)中利用表示系数构造对同类数据加权,对原空间中相关性强的两个样本采用相应较大的权值,反之采用较小的权值,其主要目的是在最小化式的过程中,保持样本在投影前后具有一致的相关结构信息。式中的参数 $\alpha > 0$,主要用来控制类内样本的紧致性, α 越大,类内样本的紧致性越强。

将式(13)转化为矩阵形式

$$\begin{aligned} \min_P \sum_{i,j=1}^n \|\mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \hat{\mathbf{x}}_j\| \hat{\mathbf{W}}_{ij}^{(w)} = & \text{tr} \left(\mathbf{P}^T \left(\sum_{i,j=1}^n (\mathbf{x}_i - \hat{\mathbf{x}}_j) \hat{\mathbf{W}}_{ij}^{(w)} (\mathbf{x}_i - \hat{\mathbf{x}}_j)^T \right) \mathbf{P} \right) = \\ & \text{tr} \left(\mathbf{P}^T \left(\sum_{i,j=1}^n (\mathbf{x}_i \hat{\mathbf{W}}_{ij}^{(w)} \mathbf{x}_i^T - \mathbf{x}_i \hat{\mathbf{W}}_{ij}^{(w)} \hat{\mathbf{x}}_j^T - \right. \right. \\ & \left. \left. \hat{\mathbf{x}}_j \hat{\mathbf{W}}_{ij}^{(w)} \mathbf{x}_i^T + \hat{\mathbf{x}}_j \hat{\mathbf{W}}_{ij}^{(w)} \hat{\mathbf{x}}_j^T) \right) \mathbf{P} \right) = \\ & \text{tr} \left(\mathbf{P}^T \mathbf{X} \left(\hat{\mathbf{D}}^{(w)} - \mathbf{X} \hat{\mathbf{W}}^{(w)} - \hat{\mathbf{W}}^{(w)} + \hat{\mathbf{D}}^{(w)} \right) \hat{\mathbf{X}}^T \mathbf{P} \right) = \\ & \text{tr} \left(\mathbf{P}^T \mathbf{X} \mathbf{S}_w \hat{\mathbf{X}}^T \mathbf{P} \right) \end{aligned} \quad (14)$$

式中, $\hat{\mathbf{D}}^{(w)}$ 是对角矩阵,对角元素 $\hat{D}_{ii}^{(w)} = \sum_{j=1}^n \hat{\mathbf{W}}_{ij}^{(w)}$ 。
 $\mathbf{S}_w = \hat{\mathbf{D}}^{(w)} - \mathbf{X} \hat{\mathbf{W}}^{(w)} - \hat{\mathbf{W}}^{(w)} + \hat{\mathbf{D}}^{(w)}$ 。

对于特征提取问题,为了提高算法在低维空间的判别能力,需要最小化类内距离,提高类内紧致性;同时最大化类间距离,提高类间可分性。为此,根据MMC思想,结合式(14)和RLSDP算法中的式(8),RLSWDP的代价函数定义为

$$\begin{aligned} \max_P \text{tr}(\mathbf{P}^T \mathbf{S}_b \mathbf{P}) - \text{tr}(\mathbf{P}^T \mathbf{X} \mathbf{S}_w \hat{\mathbf{X}}^T \mathbf{P}) = & \max_P \text{tr}(\mathbf{P}^T (\mathbf{S}_b - \mathbf{X} \mathbf{S}_w \hat{\mathbf{X}}^T) \mathbf{P}) \end{aligned} \quad (15)$$

式(15)是一个二次凸函数,类似于RLSDP算法,可以通过特征值分解获得最优投影矩阵 $\mathbf{P}$ 。

$$(\mathbf{S}_b - \mathbf{X} \mathbf{S}_w \hat{\mathbf{X}}^T) \mathbf{P} = \gamma \mathbf{P} \quad (16)$$

假设式(16)的 d 个最大特征值 $\gamma_1 \geq \gamma_2 \geq \dots \geq \gamma_d$ 对应的特征向量为 $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_d$,则最优投影矩阵 $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_d]$ 。

2.2 算法步骤

RLSWDP算法的流程分为以下4个步骤:

步骤1:为避免小样本引起奇异值问题,使用经典的主成分分析法对训练数据进行预处理,处理后的数据表示为 $\tilde{\mathbf{X}} = \mathbf{P}_{\text{pca}}^T \mathbf{X}$;

步骤2:根据式计算协同表示系数 $\mathbf{r}$,利用式(10)和式(13)构造加权矩阵 $\mathbf{W}^{(b)}$ 和 $\mathbf{W}^{(w)}$,并进一步计算矩阵 $\mathbf{S}_b = \mathbf{D}^{(b)} - \mathbf{W}^{(b)}$ 和 $\mathbf{XS}_w\hat{\mathbf{X}}^T$;

步骤3:根据式(16)计算降维矩阵 $\mathbf{P}$;

步骤4:最终,对任意样本 $\mathbf{x}$ 的降维投影结果为 $\mathbf{y} = \mathbf{P}^T \mathbf{P}_{\text{per}}^T \mathbf{x}_0$.

3 实验与结果分析

为了验证文中提出的RLSWDP算法的通用性和有效性,我们在人脸数据集和雷达数据集上分别进行验证。

3.1 特征提取性能分析

在YALE人脸数据集上,将文中提出的RLSWDP算法与RLSDP基线算法进行对比,YALE数据集的详细信息参见表1。

表1 YALE数据集描述

参数	参数值
样本大小	32×32
类别数	15
每类样本数	11
样本数目	165

对比式(7)和式(12),文中的RLSWDP算法与RLSDP算法的主要区别有两个方面。其一,RLSWDP算法使用全部的重构系数 $\mathbf{r}_i$ 代替RLSDP算法中使用的同类重构系数 $\mathbf{r}_i^+$;其二,在RLSDP算法的基础上,RLSWDP算法通过引入加权矩阵进一步实现了类内样本的距离的最小化。下面重点分析上述两个改进的优势。

第一,RLSWDP算法使用全部的重构系数 $\mathbf{r}_i$ 可以获得更小的重构误差。重构系数 $\mathbf{r}_i$ 代表所有样本在重构 $\mathbf{x}_i$ 时的贡献值。由于同类样本相似性较强, $\mathbf{r}_i$ 中较大系数多来源于 $\mathbf{x}_i$ 的同类样本。当每类训练样本较少或者类别间相似性较大时, $\mathbf{r}_i$ 中部分较大系数来自于其他类别的样本。此时,RLSDP算法只考虑同类重构系数 $\mathbf{r}_i^+$ 而忽略样本间的重构系数必然会导致较大的重构误差,而RLSWDP算法使用全部的重构系数 $\mathbf{r}_i$ 依然可以获得较小的重构误差。为了直观说明,我们选取YALE人脸数据集中前两类样本(共22个样本)为例,统计上述两种重构系数对重构误差的差异,结果如图2所示。从

图2可以看出,RLSWDP使用全部的表示系数可以获得更小、更稳定的重构误差。根据代价函数式(11)和式(15),更小的重构误差意味着更大的函数值,这与最大化代价函数的目标是一致的,因此,RLSWDP算法理论上可以获得更好的分类性能。




图2 RLSDP和RLSWDP中使用不同表示系数的重构误差对比

第二,RLSWDP算法通过最小化类内样本之间的距离提升类内样本之间的紧致性,进而提高样本在投影空间中的判别性。为了显性体现RLSWDP算法的这一优势,根据式 $\mathbf{W}_{ij}^{(w)}$ 的定义,将式(12)转化为

$$\begin{aligned} \min_{\mathbf{P}} \sum_{i,j=1}^n & \| \mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \hat{\mathbf{x}}_j \|^2 \hat{\mathbf{W}}_{ij}^{(w)} = \\ & \sum_{i=1}^n \| \mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \hat{\mathbf{x}}_i \|^2 + \\ & \sum_{\substack{i,j=1, i \neq j \\ i,j \in \text{同类}}}^n \| \mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \hat{\mathbf{x}}_j \|^2 \alpha r_{ij} + \sum_{\substack{i,j=1, i \neq j \\ i,j \in \text{异类}}}^n \| \mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \hat{\mathbf{x}}_j \|^2 0 = \\ & \sum_{i=1}^n \left\| \mathbf{P}^T \mathbf{x}_i - \sum_{j=1}^n r_{ij} \mathbf{P}^T \mathbf{x}_j \right\|^2 + \sum_{\substack{i,j=1, i \neq j \\ i,j \in \text{同类}}}^n \| \mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \hat{\mathbf{x}}_j \|^2 \alpha r_{ij} \quad (17) \end{aligned}$$

式中,第一项表示最小化样本 $\mathbf{x}_i$ 与其重构的距离,即最小化重构误差。这与RLSDP算法中的式(7)的思路是一致的。式中的第二项表示样本 $\mathbf{x}_i$ 与其同类其他样本之间的距离,最小化该项可使得同类样本在投影空间中更加紧凑,而该项在RLSDP算法中未被考虑。因此,在投影空间中,RLSWDP算法可以获得比RLSDP算法更加紧凑的同类样本分布特性,更有利于目标分类。值得说明的是,在第二项中采用 r_{ij} 作为权值,对投影前相关性高的样本采用较大的取值,相关性小的样本采用较小的

权值。这样在最小化式(17)过程中更有利于保持样本在投影前后的相关性,这对于维持样本的局部结构信息是有利的。

为了直观展示RLSWDP算法提升类内样本的紧致性的能力,以YALE为例进行二维可视化实验。实验中,从每一类中选取4张图片分别训练RLSWDP和RLSDP算法,得到二维降维投影矩阵,然后将库中所有样本分别进行二维可视化投影。图3展示了两种算法对随机5类样本降维后的二维可视化图。从图中可以看出,RLSDP算法的二维投影较为分散,同类样本的聚集性较差,不同类样本间存在重叠现象。相比而言,得益于式(17)中第二项,RLSWDP算法的同类样本分布更为紧致,且不同类之间边界更为清晰,直观地反映了RLSWDP算法的优越性。




图3 RLSWP和RLSWDP算法对YALE数据集上5类样本的二维可视化图

3.2 在公开数据集上的实验结果


同样在YALE数据集上将文中提出的RLS-

WDP特征提取算法与几种流行的特征提取算法LDA^[14], MMC^[15], LLDE^[16], LPDP^[17], MFA^[18], CRP^[23], CRRP^[24]和RLSDP^[25]进行比较。

为了避免由小样本引起的奇异问题,实验中通过使用经典的主成分分析法对数据进行预处理,保留了98%的数据能量。为对比公平,对于参数化方法,都在最优参数条件下比较它们的性能。特别地,RLSWDP的参数 λ 分别设置为80、10和10,参数 α 分别设置为300、100、1000。对数据集的每一类数据,随机选择 s 个样本(表示为 s -Train)用于算法训练,余下的样本全部作为测试集用于测试。对于每一个测试集,选取不一样的训练样本 s ,测试各算法在不同训练样本下的识别性能。与多数的相关工作相似,利用最近邻方法对测试样本进行分类,来测试不同降维算法的分类性能。所有实验均在PC机完成,PC机的配置为Intel Core i7-4790, 3.50 GHz, 16G RAM。

为了减小随机选择测试样本产生可能的性能偏差,我们对每组数据都进行30次蒙特卡洛测试实验,并利用平均统计结果衡量算法性能。实验中,针对每一个数据集分别对比了各算法在不同训练样本情况下的平均识别精度(Average Recognition Accuracy, ARA)与特征维数(Feature Dimension, FD)的变化关系,以及各算法的最大平均识别精度(Maximum Average Recognition Accuracy, MARA)对比结果。

在选取训练样本 $s = 4, 5, 6$ 三种情况下测试算法性能。图4描述了各算法在不同训练样本情况下的ARA随FD的变化曲线。表2中列出了各个算法在不同训练样本情况下的MARA以及对应的FD。我们进一步对比了各算法的运行时间,表3中列出了各个算法达到MARA时的平均运行时间。



(a) 4-Train




图4 各算法在不同训练样本情况下的ARA随FD的变化曲线

表2 各算法的MARA±σ %

算法	4-Train	5-Train	6-Train
CRP	55.28±3.65 (28)	57.04±4.01 (32)	60.17±4.72 (34)
CRRP	67.83±4.16 (15)	72.16±4.29 (15)	75.77±4.67 (14)
LDA	71.20±9.30 (14)	76.67±3.84 (14)	80.30±4.42 (14)
LLDE	65.03±5.57 (13)	76.62±3.84 (15)	79.87±5.37 (15)
LPDP	71.26±3.59 (15)	75.78±3.76 (16)	78.83±4.41 (15)
MFA	72.72±3.84 (17)	76.73±3.93 (14)	80.17±3.79 (14)
MMC	68.88±4.26 (16)	71.87±4.94 (14)	75.53±4.95 (40)
RLSDP	71.30±3.48 (14)	76.07±4.05 (14)	79.20±4.86 (14)
RLSWDP	75.82±3.94 (16)	80.18±3.68 (15)	83.13±4.16 (12)

注:()中数值为对应的FD

表3 各算法达到MARA时的运行时间 s

算法	4-Train	5-Train	6-Train
CRP	1.538	2.873	5.241
CRRP	4.572	7.869	14.022
LDA	1.360	2.134	3.768
LLDE	1.418	2.347	4.095
LPDP	1.497	2.469	4.710
MFA	1.349	2.257	4.225
MMC	1.406	2.384	4.443
RLSDP	1.382	2.204	3.796
RLSWDP	1.308	2.154	3.501

RLSWDP算法包括两个参数,分别是正则化参数 λ 和类内紧致性控制参数 α 。为了评估两个参数对RLSWDP算法性能的影响,图5描述了RLSWDP算法在不同参数情况下的ARA随参数 λ 和 α 的变化关系。




图5 ARA随参数 λ 和 α 的变化

根据以上实验结果,可以得到以下结论:


1)RLSWDP是一种有效的特征提取方法。在所有对比实验中,RLSWDP取得了最好的识别精度。尤其是当训练样本比较少或特征维数较低时,RLSWDP的性能优势更为明显。主要原因是RLSWDP通过利用样本的所有表示系数,真正意义上实现了重构误差的最小化,这一点在训练样本较少时更为明显。其次,通过最小化类内样本距离提高类内样本的紧致性,从而实现最优的分类性能。

2)RLSWDP是一种高效的特征提取方法。表3中的数据 displays,相对其他方法,RLSWDP算法的运行时间最少,这表明了RLSWDP具有较高的执行效率。


3)RLSWDP在较大的参数范围内可取得稳定的识别精度。

3.3 在雷达实测数据上的实验结果


将文中特征提取方法应用于雷达杂波点迹滤除,选择支持向量机作为分类器,分析该方法在杂波点迹滤除中的应用效果。分别选取中远程、中近程和近程3个场景进行验证,图6为3个场景的原始点的距离-时间图,图7为文中方法过滤后的点迹的距离-时间图,可以发现,滤除后的点迹较完整地保留了目标点迹,同时滤除掉大量杂波。



(a) 中远程场景




(b) 中近程场景




(c) 近程场景


图6 滤除前点迹的距离-时间图



(a) 中远程场景



(a) 中近程场景



(a) 近程场景

图7 滤除后点迹的距离-时间图

为量化分析该方法的应用效果,对3个场景中原始的真实目标点迹和虚假杂波点迹数量,以及滤除的点迹数量进行了统计,数据如表4所示。数据分析结果表明,基于该特征提取算法的点迹过滤方法可对杂波点迹实现90%以上的滤除率,同时目标点迹损失率保持在1%以下。

4 结束语

本文对雷达杂波点迹滤除时的点迹特征提取方法进行了研究,针对传统判别投影算法中由于样本重构误差大和类内样本聚集性差等问题,对RLSDP算法进行改进,提出了一种正则化最小二乘加权判别投影算法。该方法利用所有的表示系数重构样本实现整体样本重构误差的最小化;同时利用表示系数构造加权矩阵,对类内样本间的距离进行加权,实现类内样本之间距离的最小化,提升同类样本的紧致性。为了量化分析和验证本文所提方法的通用性,我们利用公开数据集和雷达实测数据对本文所提方法进行了验证。公开的

表 4 点迹滤除情况统计表

场景	目标点迹			杂波点迹			备注
	总数	保留数量 (正确率)	滤除数量 (损失率)	总数	滤除数量 (滤除率)	保留数量 (虚警率)	
场景 1	7 018	6 957(99.1%)	61(0.9%)	214 561	207 937(96.9%)	6 624(3.1%)	中远程
场景 2	3 694	3 677(99.5%)	17(0.5%)	49 714	45 736(92.0%)	3 978(8.0%)	中近程
场景 3	4 971	4 943(99.4%)	28(0.6%)	61 083	55 829(91.4%)	5 254(8.6%)	近程

人脸数据集实验结果表明文中方法相对其他主流方法取得约 4% 的分类正确率提升,雷达实测数据处理结果表明,将本文方法应用到雷达杂波点迹滤除中,可滤除 90% 的杂波点迹,同时目标点迹损失率保持在 1% 以下。

参考文献:

[1] 林坚鑫,沈学勇,楼奇哲,等. 基于 AdaBoost 的雷达剩余杂波抑制方法[J]. 电光与控制,2020,27(6):53-57.

[2] ROSENBERG L. Parametric Modeling of Sea Clutter Doppler Spectra [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021,60(9):1-9.

[3] 申露,苏洪涛,汪晋,等. 基于注意力自相关机制的剩余杂波抑制方法[J]. 西安电子科技大学学报,2024,51(1):41-51.

[4] 孙延鹏,李思锐,屈乐乐. 基于多域特征融合的旋翼无人机分类识别 [J]. 雷达科学与技术, 2023, 21(4): 447-453.

[5] 邓开,张振熙,徐逸飞,等. 基于自监督联合预训练的雷达辐射源识别方法[J]. 现代雷达,2025,47(10):50-59.

[6] 袁雪,韦楠楠,张兴敢. 利用低数据率 HRRP 序列进行弹道中段目标识别[J]. 雷达科学与技术, 2023,21(5): 559-567.

[7] 邵正途,冷毅,葛代河,等. 基于小波包分解和随机森林特征选择的雷达有源干扰识别[J]. 现代雷达,2024,46(12):45-52.

[8] CUNNINGHAM J P, GHASRAMANI Z. Linear Dimensionality Reduction: Survey, Insights, and Generalizations [J]. Journal of Machine Learning Research, 2015,16(12): 2859-2900.

[9] 李志敏,张杰,黄鸿,等. 面向高光谱图像分类的半监督 Laplace 鉴别嵌入 [J]. 电子与信息学报,2015,37(4): 995-1001.

[10] GAO Quanyue, LIU Jingjing, CUI Kai, et al. Stable Locality Sensitive Discriminant Analysis for Image Recognition [J]. IEEE Transaction on Neural Networks, 2014, 54(6):49-56.

[11] 简彩仁,夏靖波. 局部系数增强判别协同表示分类法 [J]. 厦门大学学报(自然科学版),2023,62(3):487-492.

[12] 张治鹏,张李义. 基于主成分协同表示的高维数据分类方法 [J]. 武汉大学学报(工学版), 2024, 57(3): 380-387.

[13] BELHUMEUR P N, HESBANHA J P, KRIEGMAN D J. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997,19(7):711-720.

[14] BIAN Wei, TAO Dacheng. Asymptotic Generalization Bound of Fisher's Linear Discriminant Analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(12):2325-2337.

[15] LI Haifeng, JIANG Tao, ZHANG Keshu. Efficient and Robust Feature Extraction by Maximum Margin Criterion [J]. IEEE Transactions on Neural Networks, 2006,17(1): 157-165.

[16] SUGIYAMA M. Dimensionality Reduction of Multimodal Labeled Data by Local Fisher Discriminant Analysis [J]. Journal of Machine Learning Research, 2007, 8(1): 1027-1061.

[17] GUI Jie, JIA Wei, ZHU Ling, et al. Locality Preserving Discriminant Projections for Face and Palmprint Recognition [J]. Neurocomputing, 2010,73:2696-2707.

[18] YAN Shuicheng, XU Dong, ZHANG Benyu, et al. Graph Embedding and Extensions: A General Framework for Dimensionality Reduction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51.

[19] 查志远,袁鑫,张嘉超,等. 基于低秩正则联合稀疏建模的图像去噪算法 [J]. 电子与信息学报,2025,47(2): 561-572.

[20] 刘双,张永. 基于增强空谱特征网络的空间感知协同表示算法 [J]. 模式识别与人工智能, 2021, 34(3): 241-252.

[21] 李艳婷,王帅,金军委,等. 基于加权正则化协同表示的非均衡分类方法 [J]. 电子与信息学报,2023,45(7): 2571-2579.

(下转第 73 页)

基于 Roberts 直线表示的三维空间约束航迹起始算法

邵晗星¹, 郑纪彬¹, 白艳雯¹, 葛 页², 刘伯阳², 张少峰³, 魏小丹³

(1. 西安电子科技大学雷达信号处理全国重点实验室, 陕西西安 710071;

2. 中国人民解放军63610部队, 新疆库尔勒 841000; 3. 西安导航技术研究所, 陕西西安 710068)

摘要: 航迹起始是雷达目标跟踪系统中的首要环节。在现代战场复杂的高杂波环境中, 现有航迹起始方法的目标航迹起始效率和起始精确度面临严重制约。本文首先根据目标运动学特性构建多层物理约束, 通过对雷达点迹的快速筛选有效剔除无效组合, 大幅压缩后续处理规模, 提升起始效率; 其次, 为了充分利用三维量测信息, 采用了 Roberts 表示法构建空间直线轨迹的表征模型, 将点迹转化为具备抗奇异性的稳定几何特征表达, 在此基础上引入修正 Hough 变换机制, 通过参数空间动态聚类实现在强杂波背景下的高效统计累积, 以此提高航迹起始率。仿真结果表明, 在不同的杂波密度下所提方法与逻辑法和二维 Hough 变换相比, 具有更优的性能。

关键词: 航迹起始; 雷达数据处理; Hough 变换; 逻辑法

中图分类号: TN953

文献标志码: A

文章编号: 1672-2337(2026)01-0062-12

引用格式: 邵晗星, 郑纪彬, 白艳雯, 等. 基于 Roberts 直线表示的三维空间约束航迹起始算法[J]. 雷达科学与技术, 2026, 24(1): 62-73.

SHAO Hanxing, ZHENG Jibin, BAI Yanwen, et al. A Three-Dimensional Space-Constrained Track Initiation Algorithm Based on Roberts' Straight-Line Representation [J]. Radar Science and Technology, 2026, 24(1): 62-73.

A Three-Dimensional Space-Constrained Track Initiation Algorithm Based on Roberts' Straight-Line Representation

SHAO Hanxing¹, ZHENG Jibin¹, BAI Yanwen¹, GE Ye², LIU Boyang², ZHANG Shaofeng³, WEI Xiaodan³

(1. National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China;

2. Unit 63610 of PLA, Korla 841000, China; 3. Xi'an Navigation Technology Research Institute, Xi'an 710068, China)

Abstract: Track initiation is the primary step in radar target tracking systems. However, in modern battlefields, the high clutter environment significantly limits the initiation efficiency and accuracy of existing track initiation methods. Firstly, this paper constructs multi-layer physical constraints based on target kinematic characteristics. By rapidly screening of radar plots, it effectively eliminates invalid combinations, substantially reduces the scale of subsequent processing, and enhances the initiation efficiency. Secondly, to fully utilize three-dimensional measurement information, the Roberts representation method is adopted to construct a characterization model for spatial linear trajectories. This converts plots into stable geometric feature representations with anti-singularity. Building upon this, a modified Hough transform mechanism is introduced. Through random sampling and dynamic clustering in the parameter space, efficient statistical accumulation is achieved in the strong clutter background, thereby improving the track initiation rate. Simulation results demonstrate that the proposed method outperforms both the logical method and the two-dimensional Hough transform under different clutter densities.

Key words: track initiation; radar data processing; Hough transform; logical method

0 引言

在现在雷达目标跟踪系统中, 航迹起始通常是对目标跟踪的第一步, 它通过从雷达回波获得

的多个点迹中识别出真实运动目标并形成新的跟踪航迹的过程^[1-2]。这些量测点迹可能来自目标本体, 或来自环境中的杂波、干扰等^[3-4]。因此航迹起始质量关系着整个跟踪过程, 有效的起始能为后

续关联与滤波提供高质量状态初值,保障跟踪持续性;而虚假起始将直接降低输出可信度^[5]。受复杂雷达环境与量测来源不确定性的影响,航迹起始的输入量测难以有效确定,使得该问题成为数据处理领域的研究热点。

现有雷达目标航迹起始方法主要分为顺序处理与批处理两大类^[6-7]。顺序处理方法计算量小、起始速度快,在弱杂波环境下效果优异^[8-9];然而,其在强杂波下的性能急剧下降。相较之下,批处理方法虽在强杂波中能实现精准航迹起始^[10-11],但其巨大的计算开销会导致效率低下与航迹起始延迟。

M/N逻辑法是典型的顺序处理法,基于“连续多帧关联确认”原则,通过检测目标在 N 次扫描中至少出现 M 次来区分真实目标与随机杂波,因计算实时性强被广泛应用。余沙等^[12]通过两阶段架构解决高杂波航迹起始问题,通过前端网格聚类分割目标点并滤除杂波,后端改进逻辑法采用动态波门与阶段性M/N规则起始航迹。姚直象等^[13]针对在背景干扰下易产生虚假航迹的问题,提出一种基于逻辑法的宽带声接触航迹起始算法。张星等^[14]针对探测系统航迹起始的计算效率问题,提出一种融合斜距信息的改进M/N逻辑法。该方法在传统M/N逻辑法基础上,引入斜距量测值作为二次波门约束。这些方法提升了算法在强杂波环境下的抗扰性。然而,M/N逻辑法是通过多帧关联计数完成起始,这些方法未考虑点迹具有的空间直线特征,仅依赖运动门限的设置,在强杂波环境下难以保证起始性能。

Hough变换航迹起始法是基于批处理的典型方法^[15]。其核心机制是将探测点迹投射至参数空间实现积累,并通过阈值检测累积结果,一旦某单元的累积量满足阈值判据,便触发一条航迹起始。该方法具备一次处理多点迹并批量起始航迹的特点。薛俊杰等^[16]融合序列Hough变换与逻辑法破解高杂波环境航迹起始难题,通过逐帧独立Hough累积避免无效投票,利用峰值聚类自适应提取目标点,逻辑法关联验证抑制虚假轨迹。张耀升等^[17]为了在强杂波的环境下有效地起始航迹,使用标签记录回波数据的时序信息,并通过速度门限和时序特征信息对截获的数据进行关联,同时

结合Hough变换的方法,可以在低概率目标点迹截获下实现航迹起始。这些方法利用Hough变换的积累特性,在高杂波场景中能够获得较高的航迹起始率。然而,针对强机动目标,这些方法主要依赖二维平面点迹信息进行起始跟踪,未能充分利用雷达探测中的多维信息,在高杂波场景中信息利用不足可能会无法适应多变的跟踪场景。

现代战场环境下目标机动性急剧提升,隐身战机等高速目标的航迹必须在极短的时间内完成起始,否则将直接导致后续跟踪环节失效^[18]。而雷达系统处理大量点迹,若起始阶段误将杂波确认为目标,不仅产生大量无效计算负载,更会抢占真实目标的跟踪资源。因此,必须同时对动态场景下的实时处理效率与起始精度进行协同权衡^[19]。常规的基于Hough变换的航迹起始方法仅考虑二维信息,造成信息损失。为此,本文提出一种基于Roberts直线表示的三维空间约束航迹起始算法。首先应用目标运动学先验信息和物理特性对点迹进行粗筛,降低待处理数据量,提高目标起始速度;随后为了充分利用三维量测信息,采用Roberts表示法构建空间直线轨迹的表征模型,并采用修正Hough变换框架,以此提高强杂波干扰下的航迹起始率。

1 基于三维空间约束的航迹起始方法

基于三维空间约束的航迹起始方法在接收到雷达连续多帧量测后,首先通过运动学物理约束对原始点迹进行高效粗筛,降低高杂波环境下的数据量以避免直接对所有点迹作参数空间变换导致的庞大计算量;之后将筛选后的候选点迹送入起始流程,利用高效无奇异的Roberts三维直线表示法,通过定义旋转平面 B 及投影坐标,以4个参数唯一表征目标匀速直线运动轨迹,描述潜在目标运动;最终基于修正的Hough变换框架,计算直线Roberts参数,并在参数空间进行统计加权累积,依据量测噪声特性设定归一化距离卡方门限,实现航迹的鲁棒起始。

1.1 三维空间直线的Roberts表示法

在航迹起始算法中,新目标的初始状态完全未知,通常被假设为匀速直线运动,因此需要用合

适的直线模型来描述目标轨迹。为了准确处理雷达量测点并判断它们是否共线,需要一种有效的方式来表示空间中的直线。常用的三维空间直线表示法包括 Roberts 和 Plucker 表示法。Plucker 坐标表示法虽然能够完整描述一条空间直线,但其使用了 6 个参数,存在参数冗余问题。更重要的是,它在某些特殊情况下会遇到奇异性问题,需要额外的特殊处理机制,这会影响算法实现的效率和稳定性。而 Roberts 表示法^[21]仅采用 4 个参数 $(a_x, a_y, \bar{x}, \bar{y})$ 表示三维空间中的直线,其参数数目较 Plucker 坐标显著减少,在避免冗余的同时,也通过特定的构造方式消除了奇异性问题,是更高效且稳健的空间直线描述方式,下文将对直线的 Roberts 表示法进行详细介绍。

在三维直角坐标系 (x, y, z) 三维空间中最直观的直线表示法是点向式:

$$L: \{p \mid \mathbf{a}\} \quad (1)$$

式中, $p = (p_x, p_y, p_z)$ 为直线上的一个定点, $\mathbf{a} = (a_x, a_y, a_z)$ 是其方向向量,该方法表示共需 6 个标量参数。但是这种通过 6 个变量进行表示较为冗余,为了优化表示,引入单位方向向量约束和正交位置约束,可减少两个变量,其中单位方向向量约束为

$$\|\mathbf{a}\| = 1 \Rightarrow a_x^2 + a_y^2 + a_z^2 = 1 \quad (2)$$

约束后自由度可以降为 2。

同时正交约束满足:

$$p \perp \mathbf{a} \quad (3)$$

$$p \cdot \mathbf{a} = p_x a_x + p_y a_y + p_z a_z = 0 \quad (4)$$

该约束固定了 p 为直线到坐标原点的垂足,将位置自由度降至 2。这种表示利用单位向量 $\mathbf{a}$ 和正交约束下的 p ,理论上形成 4 自由度表示。尽管参数数量匹配了自由度,奇异性问题本质上仍未解决。当方向向量与各直角平面垂直时,直线表示会出现奇异性问题。该奇异性问题导致此类直线在 Hough 变换中无法建立统一的累积空间,严重影响变换的完备性。

为克服上述奇异性难题,Roberts 提出了一种四参数表示法。其核心思想是避免直接参数化方向向量 $\mathbf{a}$,转而利用其在标准坐标系中的投影效果来隐式表示方向和平面的位置关系,从而规避方

向参数本身的奇点问题。首先定义平面 B ,如图 1 所示,一个经过坐标原点 O 且其法向量平行于直线方向向量 $\mathbf{a}$ 的平面,平面 B 实质上是所有与 $\mathbf{a}$ 正交的向量构成的空间的二维子空间。Roberts 表示法的直线是一个四元组 $(a_x, a_y, \bar{x}, \bar{y})$,其中 a_x 和 a_y 的定义同点向式,而 $\bar{x}$ 和 $\bar{y}$ 是点 p 在平面 B 上二维直角坐标系内的投影坐标。但是要计算 $\bar{x}$ 和 $\bar{y}$ 首先需要确定 B 平面内的坐标框架。Roberts 表示法的核心在于在平面 B 上构建一个特定的二维直角坐标系来表示点 p ,首先定义旋转矩阵,该矩阵将原坐标系的 z 轴旋转至与方向向量 $\mathbf{a}$ 对齐,其中旋转矩阵 A 表示为

$$A = \begin{bmatrix} 1 - \frac{a_x^2}{1 + a_z} & -\frac{a_x a_y}{1 + a_z} & a_x \\ -\frac{a_x a_y}{1 + a_z} & 1 - \frac{a_y^2}{1 + a_z} & a_y \\ -a_x & -a_y & a_z \end{bmatrix} \quad (5)$$




图1 Roberts表示法示意图

同时,同样受到单位向量方向约束条件的保证,该旋转矩阵在 z 轴与单位向量平行时同样成立,所以没有奇异情况出现,适合统一 Hough 累积空间的构建。这时原三维坐标系中的 x 轴和 y 轴映射为平面 B 内的坐标轴 x' 和 y' ,所以点 p 在平面 B 的投影 $\bar{x}$ 和 $\bar{y}$ 可以表示为

$$\bar{x} = p \cdot A\mathbf{x} = \left(1 - \frac{a_x^2}{1 + a_z}\right)p_x - \frac{a_x a_y}{1 + a_z}p_y - a_x p_z \quad (6)$$

$$\bar{y} = p \cdot A\mathbf{y} = -\frac{a_x a_y}{1 + a_z}p_x + \left(1 - \frac{a_y^2}{1 + a_z}\right)p_y - a_y p_z \quad (7)$$

通过 Roberts 表示法,参数复杂度降低,减少了参数

搜索空间维度且无冗余运算。同时规避了方向向量在特殊方向处固有的导数和拓扑奇点问题。

1.2 基于 Roberts 表示法的航迹起始方法

Roberts 表示法通过四参数量化有效消除了三维空间直线描述中的奇异性问题。然而,若仿照标准的 Hough 变换框架应用 Roberts 表示法,需在一个四自由度的参数空间中对所有采样点进行穷举式搜索与累加。这一过程需要通过离散化参数单元并将每个点映射至相应区间进行累积判断^[21]。该方法的计算开销庞大,导致累积效率受到严重制约^[22]。因此如果对所有的量测都进行三维参数空间变换,将会占用大量资源,起始效率将会大幅度下降。考虑到目标起始的速度关系着后续跟踪,且部分量测组合不符合目标运动学规律,因此,本文首先通过物理先验信息和空间约束对量测点迹进行粗筛形成暂态航迹,其次,根据修正 Hough 变换的框架,计算暂态航迹对应的 Roberts 参数,最后基于归一化门限判断是否起始航迹。

1) 约束点迹筛选

设 $z_k^i, i = 1, \dots, l_k$ 表示时刻 k 的第 i 个量测点迹,其中 $z_k^i = [\rho_k^i \ \theta_k^i \ \varphi_k^i]^T$, ρ_k^i 、 θ_k^i 和 φ_k^i 分别表示径向距离、方位角和俯仰角。假定雷达在第 k 、 $k+1$ 和 $k+2$ 扫描时刻分别接收到三帧量测,分别为 z_k^i 、 z_{k+1}^j 和 z_{k+2}^m 。在真实的战场中目标的运动需要符合物理规律,目标的特性导致了运动存在着限制,因此,首先对雷达量测点迹方位角和俯仰角进行直接约束。同时速度是衡量一个目标变化的重要指标,不同的目标径向速度存在着显著的差别,因此假设方位角和俯仰角的门限分别为 $\theta_{\max}$ 和 $\varphi_{\max}$ 。对目标运动特性分析,获得目标的极大径向速度 $V_{\max}$ 和最小径向速度 $V_{\min}$,之后对雷达获得的不同帧之间所有量测组合进行遍历求解,获得第 k 帧和第 $k+1$ 帧量测间的径向速度 V_{ij} ,方位角之差 θ_{ij} ,俯仰角之差 φ_{ij} ,以及第 $k+1$ 帧和第 $k+2$ 帧量测间的速度 V_{jm} ,方位角之差 θ_{jm} ,俯仰角之差 φ_{jm} :

$$\Delta_k = \begin{bmatrix} V_{ij} = \frac{|\rho_{k+1}^j - \rho_k^i|}{T} \\ \theta_{ij} = |\theta_{k+1}^j - \theta_k^i| \\ \varphi_{ij} = |\varphi_{k+1}^j - \varphi_k^i| \end{bmatrix} \quad (8)$$

$$\Delta_{k+1} = \begin{bmatrix} V_{jm} = \frac{|\rho_{k+2}^m - \rho_{k+1}^j|}{T} \\ \theta_{jm} = |\theta_{k+2}^m - \theta_{k+1}^j| \\ \varphi_{jm} = |\varphi_{k+2}^m - \varphi_{k+1}^j| \end{bmatrix} \quad (9)$$

式中, T 为量测采样间隔。

将三帧量测组合中 Δ_k 、 Δ_{k+1} 不符合门限的组合直接剔除。保留符合约束的组合进行下一步处理。

2) Roberts 参数求解

当空间中的多个采样点共线时,计算出的 Roberts 参数会呈现高度相似性。通过对这些计算出的参数组合进行累积计数,当某组参数累积值超过预设门限,即判定发现同一直线上的多个点迹,认为它们来自于同一个目标,从而达成直线航迹识别目标^[23]。

在三维空间中任意给定两点 (x_1, y_1, z_1) 和 (x_2, y_2, z_2) 可确定一条直线。首先计算直线的单位方位方向向量:

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (z_1 - z_2)^2} \quad (10)$$

$$(a_x, a_y, a_z) = \left(\frac{x_1 - x_2}{d}, \frac{y_1 - y_2}{d}, \frac{z_1 - z_2}{d} \right) \quad (11)$$

在本文中,将量测作为 3 维空间点进行计算。

当 a_z 小于 0 时,对单位向量的每个分量取负值,以保证单位向量的约束关系。然后,基于位置约束和直线方程,解算出原点 O 到该直线的垂足点坐标:

$$p_x = \frac{(y_2 - y_1)(x_1 y_2 - x_2 y_1) + (z_2 - z_1)(x_1 z_2 - x_2 z_1)}{d^2} \quad (12)$$

$$p_y = \frac{(x_2 - x_1)(y_1 x_2 - y_2 x_1) + (z_2 - z_1)(y_1 z_2 - y_2 z_1)}{d^2} \quad (13)$$

$$p_z = \frac{(x_2 - x_1)(z_1 x_2 - z_2 x_1) + (y_2 - y_1)(z_1 y_2 - z_2 y_1)}{d^2} \quad (14)$$

通过旋转矩阵将垂足映射至平面 B ,即可获取采样直线的 Roberts 参数四元组。但是在真实环境中,受到各种因素影响实际目标采样会受点坐标误差影响,导致 Roberts 参数计算结果具有不确定性,从而引发两次采样直线参数是否一致的判别问题。常规解决策略是根据量测误差预设一个容错阈值,若两参数间的距离量度小于该阈值,则判

定它们为相同直线,来自于同一个目标。因此,定义参数四元组的距离模型及确定阈值选取方法,成为解决该问题的核心。进一步地,可通过在真值附近进行一阶泰勒展开分析误差传播特性:

$$\bar{x} = \bar{x}_0 + \frac{\partial \bar{x}}{\partial x_1} dx_1 + \frac{\partial \bar{x}}{\partial y_1} dy_1 + \frac{\partial \bar{x}}{\partial z_1} dz_1 + \frac{\partial \bar{x}}{\partial x_2} dx_2 + \frac{\partial \bar{x}}{\partial y_2} dy_2 + \frac{\partial \bar{x}}{\partial z_2} dz_2 \quad (15)$$

式中,

$$\frac{\partial \bar{x}}{\partial x_1} = -\frac{2a_x}{d} p_x + \frac{3a_x^2 + 2a_x^2 a_z - a_z - 1}{(1 + a_z)^2 d} p_z - \frac{a_x(2x_1 z_2 - x_2 z_1 - x_2 z_2)}{(1 + a_z)d^2} - \frac{a_y y_2 + a_z z_2}{d} \quad (16)$$

$$\frac{\partial \bar{x}}{\partial y_1} = -\frac{2a_y}{d} p_x + \frac{a_x a_y (3 + 2a_z)}{(1 + a_z)^2 d} p_z + \frac{2x_2 y_1 - x_1 y_2 - x_2 y_2 + 2a_y(x_2 z_1 - x_1 z_2)}{(1 + a_z)d^2} \quad (17)$$

$$\frac{\partial \bar{x}}{\partial z_1} = -\frac{2a_z}{d} p_x + \frac{a_x(1 + 2a_z)}{(1 + a_z)d} p_z + \frac{a_x(a_x x_2 + a_y y_2)}{(1 + a_z)d} + \frac{2x_2 z_1 - x_2 z_2 - x_1 z_2}{d^2} \quad (18)$$

$$\frac{\partial \bar{x}}{\partial x_2} = \frac{2a_x}{d} p_x - \frac{3a_x^2 + 2a_x^2 a_z - a_z - 1}{(1 + a_z)^2 d} p_z - \frac{a_x(2x_2 z_1 - x_1 z_1 - x_1 z_2)}{(1 + a_z)d^2} + \frac{a_y y_1 + a_z z_1}{d} \quad (19)$$

$$\frac{\partial \bar{x}}{\partial y_2} = \frac{2a_y}{d} p_x - \frac{a_x a_y (3 + 2a_z)}{(1 + a_z)^2 d} p_z + \frac{2x_1 y_2 - x_1 y_1 - x_2 y_1 + 2a_y(x_1 z_2 - x_2 z_1)}{(1 + a_z)d^2} \quad (20)$$

$$\frac{\partial \bar{x}}{\partial z_2} = \frac{2a_z}{d} p_x - \frac{a_x(1 + 2a_z)}{(1 + a_z)d} p_z - \frac{a_x(a_x x_1 + a_y y_1)}{(1 + a_z)d} + \frac{2x_1 z_2 - x_1 z_1 - x_2 z_1}{d^2} \quad (21)$$

式中各项微分可理解为采样点坐标噪声,通过这种形式可以建立误差参数与采样噪声的显式关联。基于同构推导原理,同样可将 $\bar{y}$ 展开为噪声向量的线性叠加形式:

$$\frac{\partial \bar{y}}{\partial x_1} = -\frac{2a_x}{d} p_y + \frac{a_x a_y (3 + 2a_z)}{(1 + a_z)^2 d} p_z +$$

$$\frac{2x_1 y_2 - x_2 y_1 - x_2 y_2 + 2a_x(y_2 z_1 - y_1 z_2)}{(1 + a_z)d^2} \quad (22)$$

$$\frac{\partial \bar{y}}{\partial y_1} = -\frac{2a_y}{d} p_y + \frac{3a_y^2 + 2a_y^2 a_z - a_z - 1}{(1 + a_z)^2 d} p_z - \frac{a_y(2y_1 z_2 - y_2 z_1 - y_2 z_2)}{(1 + a_z)d^2} - \frac{a_x x_2 + a_z z_2}{d} \quad (23)$$

$$\frac{\partial \bar{y}}{\partial z_1} = -\frac{2a_z}{d} p_y + \frac{a_y(1 + 2a_z)}{(1 + a_z)d} p_z + \frac{a_y(a_x x_2 + a_y y_2)}{(1 + a_z)d} + \frac{2y_2 z_1 - y_1 z_2 - y_2 z_2}{d^2} \quad (24)$$

$$\frac{\partial \bar{y}}{\partial x_2} = \frac{2a_x}{d} p_y - \frac{a_x a_y (3 + 2a_z)}{(1 + a_z)^2 d} p_z + \frac{2x_2 y_1 - x_1 y_1 - x_1 y_2 + 2a_x(y_1 z_2 - y_2 z_1)}{(1 + a_z)d^2} \quad (25)$$

$$\frac{\partial \bar{y}}{\partial y_2} = \frac{2a_y}{d} p_y - \frac{3a_y^2 + 2a_y^2 a_z - b_z - 1}{(1 + a_z)^2 d} p_z - \frac{a_y(2y_2 z_1 - y_1 z_1 - y_1 z_2)}{(1 + a_z)d^2} + \frac{a_x x_1 + a_z z_1}{d} \quad (26)$$

$$\frac{\partial \bar{y}}{\partial z_2} = \frac{2a_z}{d} p_x - \frac{a_y(1 + 2a_z)}{(1 + a_z)d} p_z - \frac{a_y(a_x x_1 + a_y y_1)}{(1 + a_z)d} + \frac{2y_1 z_2 - y_1 z_1 - y_2 z_1}{d^2} \quad (27)$$

显然, $\bar{x}, \bar{y}$ 的噪声与采样点的坐标位置有关,尤其与采样点间距呈显著反比关系。因此,增大采样点间距可有效抑制估测方差。除此之外Roberts参数中角度参数亦可解析为线性噪声叠加模型:

$$a_x = a_{x_0} + \frac{\partial a_x}{\partial x_1} dx_1 + \frac{\partial a_x}{\partial x_2} dx_2 \quad (28)$$

式中,

$$\frac{\partial a_x}{\partial x_1} = \frac{d^2 - 2(x_1 - x_2)^2}{d^3} \quad (29)$$

$$\frac{\partial a_x}{\partial x_2} = \frac{2(x_1 - x_2)^2 - d^2}{d^3} \quad (30)$$

同样角度参数 a_y 也有相似的表达式:

$$a_y = a_{y_0} + \frac{\partial a_y}{\partial y_1} dy_1 + \frac{\partial a_y}{\partial y_2} dy_2 \quad (31)$$

式中,

$$\frac{\partial a_y}{\partial y_1} = \frac{d^2 - (y_1 - y_2)^2}{d^3} \quad (32)$$

$$\frac{\partial a_y}{\partial y_2} = \frac{(y_1 - y_2)^2 - d^2}{d^3} \quad (33)$$

假设每个采样点的噪声相互独立,两次直线抽样的4个采样点的Roberts参数归一化距离可以表示为

$$D(R_1, R_2) = (\bar{x}_1 - \bar{x}_2)^2 / \sum_{i=1,2} \left(\frac{\partial \bar{x}_1}{\partial x_i} \sigma_{x_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial \bar{x}_2}{\partial x_i} \sigma_{x_i} \right)^2 + \sum_{i=1,2} \left(\frac{\partial \bar{x}_1}{\partial y_i} \sigma_{y_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial \bar{x}_2}{\partial y_i} \sigma_{y_i} \right)^2 + \sum_{i=1,2} \left(\frac{\partial \bar{x}_1}{\partial z_i} \sigma_{z_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial \bar{x}_2}{\partial z_i} \sigma_{z_i} \right)^2 + (\bar{y}_1 - \bar{y}_2)^2 / \sum_{i=1,2} \left(\frac{\partial \bar{y}_1}{\partial x_i} \sigma_{x_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial \bar{y}_2}{\partial x_i} \sigma_{x_i} \right)^2 + \sum_{i=1,2} \left(\frac{\partial \bar{y}_1}{\partial y_i} \sigma_{y_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial \bar{y}_2}{\partial y_i} \sigma_{y_i} \right)^2 + \sum_{i=1,2} \left(\frac{\partial \bar{y}_1}{\partial z_i} \sigma_{z_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial \bar{y}_2}{\partial z_i} \sigma_{z_i} \right)^2 + (a_{x1} - a_{x2})^2 / \sum_{i=1,2} \left(\frac{\partial a_{x1}}{\partial x_i} \sigma_{x_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial a_{x2}}{\partial x_i} \sigma_{x_i} \right)^2 + (a_{y1} - a_{y2})^2 / \sum_{i=1,2} \left(\frac{\partial a_{y1}}{\partial y_i} \sigma_{y_i} \right)^2 + \sum_{i=3,4} \left(\frac{\partial a_{y2}}{\partial y_i} \sigma_{y_i} \right)^2 \quad (34)$$

式中,求和下标1,2和3,4分别对应两次独立采样构建的Roberts参数四元组所含传感器采样点^[24],该距离量为无量纲标量。理论分析表明,其与各坐标分量存在复杂非线性耦合,且解析分布形式难以显式表征。但基于中心极限定理,多重噪声叠加效应可渐进逼近高斯分布。在传感器误差服从零均值高斯白噪声假设下,归一化距离服从自由度为15的卡方分布。取95%置信水平下的统计临界值,得阈值为23.996。

3) 基于修正Hough变换框架的算法详细流程

输入雷达在第 k 、 $k+1$ 和 $k+2$ 扫描时刻分别接收到三帧量测为 z_k^i 、 z_{k+1}^j 和 z_{k+2}^m 。

① 设置径向速度门限 $V_{\max}$ 和 $V_{\min}$,方位角门限 $\theta_{\max}$,俯仰角门限 $\varphi_{\max}$ 。

② 取雷达第 k 帧的第 i 个量测 z_k^i ,第 $k+1$ 帧的第 j 个量测 z_{k+1}^j ,第 $k+2$ 帧的第 m 个量测 z_{k+2}^m ,根据

式(8)和式(9)计算所有量测组合对应的 Δ_k 和 Δ_{k+1} ,将满足门限的量测组合保存下来。

③ 在保存的量测组合中,根据式(6)~(7)和式(10)~(11)计算第 k 帧与第 $k+1$ 帧量测的参数 $(a_{xij}, a_{yij}, \bar{x}_{ij}, \bar{y}_{ij})$,第 $k+1$ 帧与第 $k+2$ 帧量测对应的参数 $(a_{xjm}, a_{yjm}, \bar{x}_{jm}, \bar{y}_{jm})$ 。

④ 根据式(12)~(33)计算差分参数,并根据式(34)计算归一化距离,归一化距离小于参考门限的量测组合为确认航迹。

⑤ 对确认航迹进行交错起始检测:若两条航迹有两帧或以上量测重复,标记为冲突航迹对。

⑥ 计算冲突航迹对的径向速度一致性: $\Delta V = |V_{ij} - V_{jm}|$,其中 V_{ij} 和 V_{jm} 为相邻帧间径向速度。保留 ΔV 较小的航迹,移除 ΔV 较大的交错航迹,得到最终航迹集合。

整体算法流程图如图2所示。




图2 算法流程图

2 仿真实验与结果分析

为了验证所提方法的有效性,本节设置了一

个存在两个目标的仿真场景,通过航迹起始率和虚假航迹起始率对所提方法进行评估并与其他航迹起始方法进行对比,以此验证所提方法的性能。

2.1 仿真场景设置

为验证所提算法的有效性及其复杂场景下算法性能,设置两个仿真场景进行验证。

场景一:假设有两个临空高超声速目标,其飞行轨迹如图3所示,雷达位置为 $[35.6^\circ, 86^\circ, 0\text{ m}]$,雷达最远探测距离为600 km,图中轨迹红色段为雷达可观测轨迹段。




图3 航迹起始仿真场景一

场景二:假设有5个高超声速目标,其飞行轨迹如图4所示,雷达位置为 $[36.4^\circ, 66^\circ, 0\text{ m}]$,雷达最远探测距离为600 km,图中轨迹红色段为雷达可观测轨迹段。




图4 航迹起始仿真场景二

每帧数据的虚警点数服从泊松分布,泊松分布均值为 λ ,产生的虚警点按均匀分布随机地分

布在雷达视域内。速度约束条件 $v_{\min} = 5\text{ Ma}$, $v_{\max} = 20\text{ Ma}$,假设目标侧向运动导致的角度变化量为 $\Delta\alpha$,目标径向距离为 ρ_r ,目标侧向速度为 Δv ,则由侧向位置的变化与侧向角度变化量的对应关系为

$$\Delta v T \approx \frac{\pi \times \Delta\alpha}{180} \rho_r \quad (35)$$

假设 $\Delta v = 20\text{ Ma}$, $\rho_r = 600\text{ km}$,估算得到 $\Delta\alpha \approx 0.3275^\circ$,考虑到量测误差的存在,设置相邻两帧角度约束条件 $\theta_{\max} = 1^\circ$, $\varphi_{\max} = 1^\circ$;设置归一化距离门 $D_{\max}$ 为23.996。

2.2 仿真结果评价标准

在雷达航迹起始研究中,航迹起始成功率和虚假航迹率是常用的算法验证评估标准。其中航迹起始成功率是指在多次实验中成功起始的目标数目与目标总数之比。假设共进行 M 次仿真实验,在单次实验仿真中目标的个数为 N 。第 m 次实验,第 n 个目标是否成功起始的标志为 $iniflag_n^m$;航迹起始成功率为 $iniPd$ 。

$$iniflag_n^m = \begin{cases} 1 & \text{第} m \text{次实验第} n \text{个目标成功起始} \\ 0 & \text{第} m \text{次实验第} n \text{个目标未能起始} \end{cases} \quad (36)$$

$$iniPd = \frac{\sum_{m=1}^M \sum_{n=1}^N iniflag_n^m}{M \times N} \quad (37)$$


需要说明的是,在仿真实验中,采用3个量测点进行起始,这3个量测点与对应目标量测点相同才会判定起始成功。

虚假航迹起始率同样是一个重要的衡量指标,以此来评估在每次实验中非真实目标被起始的概率。具体指的是在多次仿真实验中,起始的非目标航迹数目与起始总航迹数目之比。假设共进行 M 次仿真实验,单次实验仿真目标个数为 N 。第 m 次实验起始航迹总数为 $initranum_m$,其中非目标航迹数为 $iniFtranum_m$;虚假航迹起始率为 $iniPf$ 。


$$iniPf = \frac{\sum_{m=1}^M iniFtranum_m}{\sum_{m=1}^M initranum_m} \quad (38)$$

2.3 仿真结果对比与分析


为了验证在强杂波环境下所提出的航迹起始算法的性能,本文通过对比不同杂波密度参数时运用的不同方法来验证所提算法的性能。仿真场景一在不同杂波密度下量测分布如图5所示,为不同杂波密度下的量测点迹分布图,其中红色点为目标量测点迹。




(a) $\lambda = 200$ 量测点迹分布图



(b) $\lambda = 250$ 量测点迹分布图



(c) $\lambda = 300$ 量测点迹分布图




(d) $\lambda = 350$ 量测点迹分布图


图5 场景一在不同杂波密度下量测点迹分布图

经过多重规则的约束筛选后,保留得到的量测点迹如图6所示,从图6中可以看出,不符合物理约束后的量测点迹被剔除,大幅度降低了进行参数空间变换的数据量。


经过基于Roberts的三维Hough变换筛选,最终得到的起始航迹如图7所示。




(a) $\lambda = 200$ 物理约束初筛后量测点迹分布图



(b) $\lambda = 250$ 物理约束初筛后量测点迹分布图



(c) $\lambda = 300$ 物理约束初筛后量测点迹分布图



(d) $\lambda = 350$ 物理约束初筛后量测点迹分布图

图 6 场景一在物理约束初筛后量测点迹分布图




图 7 场景一航迹起始结果图


为了验证所提方法的性能,与不同算法经过 100 次蒙特卡洛仿真后的结果进行对比。表 1 显示了当杂波密度参数 λ 分别为 200、250、300 和 350 时,所提方法与逻辑法和二维修正 Hough 变换的航迹起始率和虚假航迹起始率对比。从表 1 中可以看出随着 λ 的增大,航迹起始率降低,而

且由于杂波点变多,量测数据量增大,虽然经过多层约束,筛掉大多数点迹,但过门限的点迹仍有所增加,虚假航迹起始率在逐步上升。从表 1 中可以看出所提算法的航迹起始成功率最高,虚假航迹起始率最低,证明了目标在高杂波环境下的起始性能。


表 1 场景一在不同杂波密度参数下不同航迹起始方法性能

方法	参数	不同杂波密度参数值			
		$\lambda = 200$	$\lambda = 250$	$\lambda = 300$	$\lambda = 350$
逻辑法	<i>iniPd</i>	0.955	0.935	0.895	0.880
	<i>iniPf</i>	0.154	0.197	0.241	0.325
二维修正 Hough 变换	<i>iniPd</i>	0.955	0.945	0.925	0.914
	<i>iniPf</i>	0.072	0.135	0.171	0.259
所提方法	<i>iniPd</i>	0.990	0.982	0.975	0.968
	<i>iniPf</i>	0.048	0.079	0.141	0.168

仿真场景二在不同杂波密度下量测分布如图 8 所示,其中红色点为目标点迹。



(a) $\lambda = 200$ 量测点迹分布图



(b) $\lambda = 250$ 量测点迹分布图




(c) $\lambda = 300$ 量测点迹分布图(b) $\lambda = 250$ 物理约束初筛后量测点迹分布图(d) $\lambda = 350$ 量测点迹分布图

图8 场景二在不同杂波密度下量测点迹分布图

经过多重规则的约束筛选后,仿真场景二在不同杂波密度下保留得到的量测点迹如图9所示。

经过基于Roberts的三维Hough变换筛选,场景二最终得到的起始航迹如图10所示。




(c) $\lambda = 300$ 物理约束初筛后量测点迹分布图(d) $\lambda = 350$ 物理约束初筛后量测点迹分布图

图9 场景二在物理约束初筛后量测点迹分布图

同样地,与不同算法经过100次蒙特卡洛仿真后的结果进行对比。表2显示了当杂波密度参数 λ 分别为200、250、300和350时,所提方法与逻辑法和二维Hough变换的航迹起始率和虚假航迹起始率对比。从表2中可以看出,在目标相距较近的情况下,由于交错航迹的出现,逻辑法和二维修正Hough变换方法的虚假航迹率高,同时随着 λ 的增大,虚假航迹起始率在逐步上升。而所提方法

(a) $\lambda = 200$ 物理约束初筛后量测点迹分布图

考虑了交错航迹的处理,同时三维直线特征检测有效抑制了虚假航迹的产生,在密集目标场景下同样获得了良好的性能。




图10 场景二航迹起始结果图

表2 场景二在有不同杂波密度参数下不同航迹起始方法性能

方法	参数	不同杂波密度参数值			
		$\lambda = 200$	$\lambda = 250$	$\lambda = 300$	$\lambda = 350$
逻辑法	<i>iniPd</i>	0.955	0.925	0.903	0.895
	<i>iniPf</i>	0.644	0.695	0.755	0.821
二维修正	<i>iniPd</i>	0.926	0.916	0.904	0.885
Hough变换	<i>iniPf</i>	0.532	0.602	0.672	0.732
所提方法	<i>iniPd</i>	0.974	0.982	0.974	0.986
	<i>iniPf</i>	0.058	0.068	0.121	0.178

3 结束语

针对在高杂波动态场景下对目标进行航迹起始的实时处理效率与起始精度协同权衡问题,本文提出了一种基于Roberts直线表示的三维空间约束航迹起始算法。首先采用目标运动学先验约束对量测点迹进行筛选,过滤大量杂波点迹;随后为了充分利用径向距离、方位角和俯仰角三维量测信息,采用Roberts表示法构建空间直线轨迹的表征模型,将点迹转化为具备抗奇异性的稳定几何特征表达以此提高高杂波环境下目标的起始率。仿真结果表明,本文所提出的算法,与其他航迹起始算法对比,能够有效的提高目标的航迹起始率,并抑制虚假航迹起始率,提高了目标在高杂波场景中起始的鲁棒性。

参考文献:

- [1] 李天成,谢昱昕,李固冲,等.面向多目标跟踪的数据关联方法研究综述[J].雷达科学与技术,2025,23(1):10-31.
- [2] 沈光铭.基于深度学习的目标航迹起始和识别问题研究[D].合肥:合肥工业大学,2021.
- [3] ZHANG Yun, YANG Shiyu, LI Hongbo, et al. A Novel Multi-Target Track Initiation Method Based on Convolution Neural Network[C]//2017 International Workshop on Remote Sensing with Intelligent Processing, Shanghai, China: IEEE, 2017: 1-5.
- [4] WANG Zengke, ZHANG Weijie, PAN Meiyuan, et al. A Novel Track Initiation Method Based on Rule Knowledge and Deep Detection Network[C]//Sixteenth International Conference on Signal Processing Systems, Kunming, China: SPIE, 2025: 1256-1267.
- [5] 邓丽颖.一种杂波环境下高速机动目标自动起始方法[J].舰船电子对抗,2024,47(6):107-109.
- [6] 靳标,李聪,张贞凯.回波幅度信息辅助的群目标航迹起始方法[J].雷达学报,2020,9(4):723-729.
- [7] LIU Shuo, LI Hongbo, ZHANG Yun, et al. Random Forest-Based Track Initiation Method[J].The Journal of Engineering, 2019(6): 6175-6179.
- [8] 阙晨虎,黄晓红,田子然.基于改进多密度自适应DB-SCAN的航迹起始方法[J].现代雷达,2025,47(5):27-33.
- [9] BENOUDNINE H, MECHE A, KECHE M, et al. Real Time Hough Transform Based Track Initiators in Clutter[J]. Information Sciences, 2016, 337: 82-92.
- [10] 杨鹏刚.基于中性Hough变换的多编队航迹起始运算法[D].西安:西安电子科技大学,2024.
- [11] 鹿传国,冯新喜,孔云波,等.并行Hough变换航迹起始[J].雷达学报,2013,2(3):292-299.
- [12] 余沙,陈明燕,曹建蜀.基于网格聚类 and 修正逻辑的航迹起始算法[J].计算机科学,2015,42(4):181-184.
- [13] 姚直象,柳嵩,林啸.被动宽带声接触航迹起始方法研究[J].海军工程大学学报,2025,37(3):63-68.
- [14] 张星,杜嘉薇,陈汗龙,等.一种基于斜距离信息的探测系统航迹起始算法[J].电子科技,2017,30(8):36-39.
- [15] LI Fan, XIONG Jiajun, LAN Xuhui, et al. Hypersonic Vehicle Trajectory Prediction Algorithm Based on Hough Transform[J]. Chinese Journal of Electronics, 2021, 30(5): 918-930.
- [16] 薛俊杰,陈剑,徐恒,等.复杂环境下基于序列Hough变换和逻辑法的航迹起始方法[J].无线电工程,2022,52(4):624-629.

- [17] 张耀升,邓宗平,李华. 低概率目标点迹截获下的修正 Hough 变换航迹起始方法[J]. 电子信息对抗技术, 2018,33(2):12-16.
- [18] HU Yudong,GAO Changsheng,LI Junlong, et al. Maneuver Mode Analysis and Parametric Modeling for Hypersonic Glide Vehicles [J]. Aerospace Science and Technology, 2021, 119: 107166.
- [19] YAN Junkun,JIAO Hao,PU Wenqiang, et al. Radar Sensor Network Resource Allocation for Fused Target Tracking: A Brief Review [J]. Information Fusion, 2022, 86: 104-115.
- [20] WANG Weijie,WANG Shengli,ZHANG Zhi,et al. Multi-Target Track Initiation Method Based on Support Vector Machine in Non-Uniform Strong Clutter Environment [C]//2021 IEEE 5th Information Technology, Networking, Electronic and Automation Control Conference, Xi'an,China: IEEE, 2021: 818-824.
- [21] 吴泽民,张磊,刘晗,等. 基于随机 Hough 变换的三维集中式航迹起始算法[J]. 电子学报,2013,41(5):840-847.
- [22] 包中华,卢建斌,田永华,等. 密集杂波背景下雷达微弱海面目标的修正 Hough 变换 TBD 检测新方法[J]. 电子学报,2022,50(7):1735-1743.
- [23] 聂泽东. 基于 DBSCAN 和修正 Hough 变换的多编队航迹起始算法[J]. 信息化研究,2019,45(3):22-25.
- [24] BOUKHAROUBA A. A New Algorithm for Skew Correction and Baseline Detection Based on the Randomized Hough Transform [J]. Journal of King Saud University-Computer and Information Sciences, 2017, 29(1): 29-38.

作者简介:

邵晗星 男,硕士研究生,主要研究方向为雷达目标航迹起始、数据关联。

郑纪彬(通信作者) 男,教授、博士生导师,主要研究方向为临空高超音速目标雷达探测、雷达电磁频谱智能感知。

白艳雯 女,博士研究生,主要研究方向为雷达目标航迹起始、数据关联。

葛 页 男,正高级工程师,主要研究方向为临近空间高速目标雷达探测与轨迹预测、太空态势感知。

刘伯阳 男,正高级工程师,主要研究方向为临近空间高速目标雷达探测与轨迹预测。

张少峰 男,正高级工程师,主要研究方向为雷达总体设计及信号处理。

魏小丹 女,工程师,主要研究方向为雷达总体设计。

(上接第 61 页)

- [22] GUI Jie, SUN Zhenan, JIA Wei, et al. Discriminant Sparse Neighborhood Preserving Embedding for Face Recognition[J]. Pattern Recognition, 2012,45(8):2884-2893.
- [23] YANG Wankou, WANG Zhenyu, SUN Changyin. A Collaborative Representation Based Projections Method for Feature Extraction [J]. Pattern Recognition, 2015,48(1): 20-27.
- [24] YIN Jun, WEI Lai, SONG Miao, et al. Optimized Projection for Collaborative Representation Based Classification and Its Applications to Face Recognition [J]. Pattern Recognition Letters, 2016,73(4):83-90.
- [25] YANG Wankou, SUN Changyin, ZHENG Wenming. A Regularized Least Square Based Discriminative Projec-

tions for Feature Extraction [J]. Neurocomputing, 2016, 175:198-205.

作者简介:

汪 晋 男,博士研究生,研究员,主要研究方向为雷达数据处理、模式识别。

苏洪涛(通信作者) 男,博士,教授,博士生导师,主要研究方向为自适应信号处理、雷达数据处理。

汪圣利 男,博士,研究员,主要研究方向为信息融合、雷达数据处理。

田 强 男,博士,高级工程师,主要研究方向为雷达数据处理。

基于多尺度特征匹配的小样本雷达无人机识别

孙延鹏, 石增辉, 屈乐乐

(沈阳航空航天大学电子信息工程学院, 辽宁沈阳 110136)

摘要: 为了提高在数据不足的情况下对雷达无人机的分类效果,本文提出一种基于多尺度特征增强和度量学习的小样本分类方法——基于高效网络(EfficientNet)的多尺度学习网络(EfficientNet-based Multi-scale Learning Network, EMLNet)。该方法在轻量化 EfficientNet 网络中引入高效多尺度注意力机制(Efficient Multi-scale Attention, EMA)进行特征提取,通过多尺度并行子网络与跨空间依赖建模能力,有效增强了特征的稳定性与判别能力。分类阶段通过引入基于局部特征匹配的方法,实现支持集与查询集之间的细粒度相似性建模,为提升训练稳定性与泛化性能,本文进一步结合原型损失(Prototypical Loss)与交叉熵损失(Cross-Entropy Loss)构建复合损失函数(PCE Loss),引导模型在优化类间判别性的同时保持类内特征聚集性。最后在开源的多普勒雷达数据集上开展实验,实验结果表明,所提方法在小样本场景下表现出显著的性能优势。

关键词: 无人机分类; 连续波雷达; 小样本学习; EfficientNet 网络; 度量学习; 时频图

中图分类号: TN957.5

文献标志码: A

文章编号: 1672-2337(2026)01-0074-09

引用格式: 孙延鹏, 石增辉, 屈乐乐. 基于多尺度特征匹配的小样本雷达无人机识别[J]. 雷达科学与技术, 2026, 24(1): 74-82.

SUN Yanpeng, SHI Zenghui, QU Lele. Few-Shot Radar UAV Recognition Based on Multi-Scale Feature Matching[J]. Radar Science and Technology, 2026, 24(1): 74-82.

Few-Shot Radar UAV Recognition Based on Multi-Scale Feature Matching

SUN Yanpeng, SHI Zenghui, QU Lele

(College of Electronic Information Engineering, Shenyang Aerospace University, Shenyang 110136, China)

Abstract: In order to improve the classification accuracy of radar-based UAV signals under limited data conditions, this paper proposes a few-shot classification framework EMLNet (EfficientNet-based Multi-scale Learning Network) based on multi-scale feature enhancement and metric learning. The method integrates an efficient multi-scale attention mechanism (EMA) into the lightweight EfficientNet backbone for feature extraction, which effectively enhances the stability and discriminative ability of features through multi-scale parallel sub-network with cross-spatial dependence modeling. In the classification stage, a local feature matching strategy is adopted to achieve fine-grained similarity modeling between the support set and the query set. To further improve training stability and generalization performance, a composite loss function (PCE Loss) that combines prototypical loss and cross-entropy loss is introduced to optimize inter-class discrimination while maintaining intra-class feature aggregation. Experiments are carried out on the open-source Doppler radar dataset. The experimental results demonstrate that the proposed method achieves significant performance advantages in few-shot learning scenarios.

Key words: UAV classification; continuous wave radar; few-shot learning; EfficientNet; metric learning; time-frequency map

0 引言

无人飞行器(UAV)因其成本降低和技术显著进步,在军事和民用领域得到了广泛应用^[1]。但是其非法使用也对空域以及公共安全构成了多种威

胁,例如非法毒品交易、侵犯隐私、扰乱航空秩序等^[2]。因此,针对无人机等“低、慢、小”空中目标的高效探测与识别技术,已成为当前学术界与工业界共同关注的研究热点^[3]。

传统的无人机识别方法主要基于人工特征提

取,特征构建过程高度依赖领域经验,随着深度学习快速发展,现阶段大多结合深度学习和微多普勒特征^[4-5]进行多旋翼无人机的分类,其中Zhang等人^[6]使用双频段(K波段和X波段)雷达采集微多普勒数据集,通过主成分分析(PCA)融合特征,并结合支持向量机(SVM)对直升机、四旋翼、六旋翼无人机进行分类,准确率达94.7%。然而,PCA在提取微多普勒特征中的关键信息时易造成信息的损失^[7]。Park等人^[8]基于X波段雷达生成频谱图,使用ResNet-SP卷积神经网络(CNN)对无人机(四旋翼无人机、仿生鸟MetaFly和仿生鸟Disco)进行分类,准确率达到83.39%。邴政等人^[9]结合卷积神经网络与集成学习对无人机与飞鸟分类识别,数据总规模约含4 000个无人机和5 000个飞鸟样本。

上述方法多基于较充分数据集开展研究。但在实际监测中,受非协作通信与复杂环境影响,往往难以获取足够的高质量数据,限制了传统方法的适用性。为缓解上述问题,研究者逐渐关注基于度量学习的范式,即通过学习特征间的相似性度量来辅助分类^[10]。针对信号识别中的小样本挑战,Li等人^[11]构建了端到端训练的深度最近邻神经网络,在小样本分类基准数据集上准确率提升了约17%。Liu等人^[12]提出一种循环优化度量学习方法,通过构建基于几何代数图神经网络的正向与反向预测结构,并引入循环一致性损失与预测优化模块,在多个小样本分类任务中取得显著效果。

为了提高雷达无人机识别在小样本情景下的分类性能,本文提出一种融合多尺度特征增强和度量学习的小样本分类方法。特征提取模块在高效网络(EfficientNet)引入高效多尺度注意力(EMA)并行结构,融合局部卷积与跨空间依赖建模,增强特征表达效果。分类阶段引入基于局部描述子的度量学习策略,并结合K近邻算法实现支持集与查询集之间的细粒度匹配。为提升训练稳定性和模型泛化能力,本文进一步构建了交叉熵损失与原型损失的加权融合损失函数。该方法在小样本数据情景下有效提升了分类准确率。

1 回波信号预处理

旋翼无人机的叶片旋转作为一种周期性微

动,会导致雷达回波中出现随时间变化的微多普勒频移,这种现象被称为微多普勒效应。该效应与无人机叶片的旋转速度、长度和数量等参数密切相关,通过分析微多普勒效应,可以捕捉到由叶片旋转引起的周期性频率变化,从而揭示目标的运动特性。在雷达信号处理中,短时傅里叶变换(STFT)是一种常用的时频分析方法,它通过滑动窗函数对信号进行局部截取,并对每段信号进行频谱分析,从而获得信号的时频分布。雷达接收到的基带信号可以表示为所有散射点回波的叠加:

$$z(t) = \sum_{i=1}^n a_i e^{-j\phi_i(t)} + \eta(t) \quad (1)$$

式中, a_i 为第*i*个散射体的反射系数, $\phi_i(t) = 4\pi R_i(t)/\lambda$ 为第*i*个散射体的相位调制项, $\eta(t)$ 为噪声。基带回波信号 $z(t)$ 的短时傅里叶变换数学表达式为

$$STFT(\tau, \omega) = \int_{-\infty}^{\infty} z(t) h(t - \tau) e^{-j\omega t} dt \quad (2)$$

式中, $h(t)$ 为短时傅里叶变换的窗函数, τ 为窗函数移动的位置, ω 为多普勒频率。

2 模型设计

本文所提出的EMLNet网络由特征提取模块和分类模块构成,整体结构如图1所示。

2.1 特征提取

由于本研究面向小样本雷达无人机数据场景,数据量有限,因此本文采用在小样本情况下具有良好表征能力的轻量级网络EfficientNet作为基础特征提取器。其采用复合缩放策略,在保持高精度的同时显著降低参数量和计算复杂度。然而,其核心模块MB卷积中集成的挤压与激励(Squeeze-and-Excitation, SE)注意力机制仅对通道维度进行加权处理,即通过全局池化(Global Average Pooling, GAP)建模通道间的关系,缺乏对空间信息的捕捉,导致其在局部特征表达上存在局限性,易在对无人机特征提取的过程中损失局部关键信息。

为了弥补上述缺陷,本文引入了EMA注意力机制,该模块通过构建由1×1和3×3卷积核组成的并行子网络,在不进行通道压缩的前提下,有效建

模跨尺度的空间信息。EMA 首先将输入特征划分为多个通道组,并在组内独立建模,以提升特征分布的均衡性与完整性,其每个子网络在各自尺度上生成注意力权重,随后通过跨空间的信息交互机制融合分支输出,从而实现局部细节增强与全局结构建模的协同优化,有效提升了模型在杂波背景下的识别性能。

另一方面,EMA 模块在特征提取阶段所实现的局部增强效果,与分类阶段采用的基于局部描述子的匹配策略形成良好协同。前者有助于突出局部判别性区域的细粒度特征,后者则进一步利用这些区域间的局部相似性进行细致对比,两者在不同阶段共同强化了局部结构的建模能力。




图1 整体网络模型结构

此外,与 SE 模块需要使用全连接层和 Sigmoid 激活函数计算通道注意力不同,EMA 模块不依赖全连接层,而是采用轻量卷积与全局池化,并结合矩阵点积构建位置间的响应关系,这使得 EMA 相比 SE 在参数数量和计算量上具有更明显的优势。

2.1.1 EfficientNet


EfficientNet 的核心思想是复合缩放策略 (Compound Scaling),该策略通过在不同的维度(深度、宽度、分辨率)上进行统一的缩放,从而更均衡地提升模型准确率和效率^[13],其网络结构如图2所示。

在引入复合缩放之前,EfficientNet 的基线网络结构可形式化表示为

$$\mathcal{N} = \bigodot_{i=1, \dots, S} F_i^{L_i} (X_{\langle H_i, W_i, C_i \rangle}) \quad (3)$$

其中: $\mathcal{N}$ 表示整个卷积神经网络; $\bigodot$ 表示层的组合; F_i 表示第*i*个网络阶段的模块结构; L_i 表示重复次数;输入特征张量*X*的尺寸为 $\langle H_i, W_i, C_i \rangle$,分别

表示空间维度(高度和宽度)和通道数。



(a) EfficientNet

(b) MB 卷积模块

图2 特征提取模块

模型的目标是最大化准确率,并通过调整 d, w, r 优化模型结构:

$$\max_{d,w,r} \text{Accuracy}(\mathcal{N}(d,w,r)) \quad (4)$$

式中, d, w 和 r 分别表示网络深度、宽度和分辨率的缩放系数,各个维度的含义如下:

d (Depth Scaling): 增加网络层数,提高模型表达能力;

w (Width Scaling): 增加每层的通道数,提升特征表示能力;

r (Resolution Scaling): 增加输入图像的分辨率,提高细粒度信息。

为了避免三维搜索空间带来的巨大计算成本, EfficientNet 引入了统一缩放因子 ϕ , 用幂函数统一控制3个维度的扩展:

$$d = \alpha^\phi, \quad w = \beta^\phi, \quad r = \gamma^\phi \quad (5)$$

式中, α, β, γ 为手动设定的基础扩展系数, ϕ 为可调的缩放因子。为了保持整体计算资源的可控性,需满足如下约束:

$$\text{s.t.} \quad \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 (\alpha, \beta, \gamma \geq 1) \quad (6)$$

最终,使用复合缩放策略构建的网络结构为

$$\mathcal{N}(d,w,r) = \bigodot_{i=1,\dots,s} \hat{F}_i^{\hat{L}_i} \left(X_{\langle r \cdot \hat{H}_i, r \cdot \hat{W}_i, w \cdot \hat{C}_i \rangle} \right) \quad (7)$$

为了确保网络的实际部署能力,在模型优化过程中需同时满足如下资源约束条件:

$$\text{Memory}(\mathcal{N}) \leq \text{target_memory} \quad (8)$$

$$\text{FLOPS}(\mathcal{N}) \leq \text{target_flops} \quad (9)$$

该约束条件表示:内存占用 $\text{Memory}(\mathcal{N})$ 和计算量 $\text{FLOPS}(\mathcal{N})$ 不超过目标值,这种约束优化可以平衡神经网络的性能和计算资源。 $\hat{F}_i, \hat{L}_i, \hat{H}_i, \hat{W}_i, \hat{C}_i$ 来自预训练的基线模型,依次分别表示为基准网络中预定义的第 i 层阶段、层操作、层重复次数、高度缩放、宽度缩放和通道数。通过精细调整模型的参数与计算量,优化其表现以符合给定的内存和浮点运算量限制,从而在保证高效的特征学习能力的同时,降低计算开销。

2.1.2 EMA

EMA 模块在坐标注意力机制 (Coordinate Attention, CA) 的基础上,引入并行的 1×1 和 3×3 卷积分支以及 2D 全局平均池化操作,以同时建模空间与通道维度的多尺度依赖关系^[14]。相较于 CA 模

块沿水平与垂直方向分别执行 1D 全局池化编码位置信息,EMA 通过二维空间建模增强上下文感知能力,在不引入通道压缩的前提下保留跨通道关键信息,从而在提升特征交互效率的同时,增强了模型对细粒度结构和多尺度上下文的表达能力。其结构如图 3 所示。

设输入特征图为 $\mathbf{x} \in \mathbb{R}^{C \times H \times W}$, $\mathbb{R}$ 表示实数域, C, H, W 分别表示输入的通道数、高度和宽度, $\mathbf{x}_c$ 表示第 c 个通道的输入特征图, $\mathbf{x}_c(i, j)$ 表示第 c 个通道特征图在空间位置 (i, j) 处的矩阵元素。




图3 EMA模块

CA 模块分别沿水平和垂直方向执行 1D 全局平均池化以编码方向性空间特征,其定义如下:

1) 水平方向池化(沿列方向):

$$\mathbf{z}_c^H(\mathbf{H}) = \frac{1}{W} \sum_{0 \leq i \leq W} \mathbf{x}_c(H, i) \quad (10)$$

2) 垂直方向池化(沿行方向):

$$\mathbf{z}_c^W(\mathbf{W}) = \frac{1}{H} \sum_{0 \leq j \leq H} \mathbf{x}_c(j, W) \quad (11)$$

其中, $\mathbf{z}_c^H(\mathbf{H})$, $\mathbf{z}_c^W(\mathbf{W})$ 分别表示沿列方向和行方向池化得到的通道注意力向量。相比之下,EMA 模块通过二维全局平均池化捕获完整的空间上下文信息,其定义为

$$\mathbf{z}_c = \frac{1}{H \times W} \sum_{j=1}^H \sum_{i=1}^W \mathbf{x}_c(i, j) \quad (12)$$

2.2 分类模块

传统的小样本度量学习方法通常将整幅图像编码为单一的全局特征向量,从而使用全局特征进行类别级别的距离度量,但是在无人机识别任务中,不同类型无人机的主要差异集中在旋翼微动及局部频率结构等细粒度特征上,因此只关注全局特征将会损失图像有区分度的局部信息,从而导致识别性能下降。

基于上述问题,本文在自设计的特征提取网络基础上,构建了基于局部描述子的非参数度量分类模块。该模块借鉴了文献[11]中提出的图像到类别匹配机制,结合KNN算法,采用基于局部描述子匹配的图像到类别度量方法,先通过特征提取网络提取出查询集的局部特征,再分别和每一类支持集图像提取出的局部特征向量做度量,从而充分利用局部特征信息,提升在微多普勒图等具有局部显著特征的任务中的分类效果。

需要指出的是,尽管分类模块结构上延续了文献[11]的匹配框架,但本文在训练目标上进行了改进。具体而言,引入Cross-Entropy Loss与Prototypical Loss的加权融合作为联合优化目标,以同时增强类别间的判别性与类别内的聚合性,从而进一步提升模型在小样本任务中的分类性能。

如图1的分类模块所示,支持和查询图像通过特征提取模块提取的局部特征描述子集合为

$$\Psi(X) = [\mathbf{x}_1, \dots, \mathbf{x}_m] \in \mathbb{R}^{C \times m} \quad (13)$$

式中, $\mathbf{x}_i$ 表示第 i 个局部特征, C 表示特征维度, m 表示描述符数量, 本文输入图像分辨率为 224×224 , 经特征提取网络提取后输出特征图尺寸为 $7 \times 7 \times 1280$, 因此每个局部特征维度 $C = 1280$, 每张图像包含 $m = 49 (m = H \times W)$ 个局部特征, 其中 H 、 W 分别表示输出特征图的高和宽。对于每个查询集图像的局部特征描述子 $\mathbf{x}_i$, 在支持集类别 c 中找到其 k 个最近邻局部描述子 $\hat{\mathbf{x}}_i^j \big|_{j=1}^k$, k 为预设的最近邻局部描述子数量, 然后计算 $\mathbf{x}_i$ 与每个最近邻 $\hat{\mathbf{x}}_i^j \big|_{j=1}^k$ 的余弦相似度:

$$\cos(\mathbf{x}_i, \hat{\mathbf{x}}_i^j) = \frac{\mathbf{x}_i^T \hat{\mathbf{x}}_i^j}{\|\mathbf{x}_i\| \cdot \|\hat{\mathbf{x}}_i^j\|} \quad (14)$$

将所有局部描述子之间的相似度进行求和,

计算查询图像与类别 c 的总相似度得分:

$$\Phi(\Psi(q), c) = \sum_{i=1}^m \sum_{j=1}^k \cos(\mathbf{x}_i, \hat{\mathbf{x}}_i^j) \quad (15)$$

式中, $\|\cdot\|$ 表示向量的 L_2 范数, q 表示查询图像类别, c 表示支持图像类别。

3 PCE Loss

为引导模型在小样本条件下兼顾类内特征聚合与类间判别, 本文构建了融合 Prototypical Loss 与 Cross-Entropy Loss 的复合损失函数, 以提升识别性能与泛化能力。

3.1 Prototypical Loss

Prototypical Loss 是一种基于度量学习的小样本学习任务中的损失函数^[15], 通过计算查询样本与各类别原型之间的距离, 并使用 softmax 函数将其转化为分类概率, 从而引导模型在嵌入空间中学习具有良好判别性的特征表示, 设样本 $\mathbf{x}_i$ 的特征表示为 $\mathbf{f}_\phi(\mathbf{x}_i)$, 类别 c 的原型向量 $\mathbf{p}_c$ 计算为

$$\mathbf{p}_c = \frac{1}{|S_c|} \sum_{(\mathbf{x}_i, y_i) \in S_c} \mathbf{f}_\phi(\mathbf{x}_i) \quad (16)$$

式中, 类别 c 的支持集 $S_c = \{(\mathbf{x}_i, y_i)\}_{i=1}^{n_c}$, 包括 n_c 个样本, 对于 K -Shot 任务设置, $n_c = K$, y_i 表示 $\mathbf{x}_i$ 样本的类别标签。

对于查询样本 $\mathbf{x}_q$, 计算其特征表示与各类别原型之间的距离:

$$d(\mathbf{f}_\phi(\mathbf{x}_q), \mathbf{p}_c) = \|\mathbf{f}_\phi(\mathbf{x}_q) - \mathbf{p}_c\|_2^2 \quad (17)$$

式中, $\|\cdot\|_2^2$ 表示欧式距离的平方。

然后将距离通过 softmax 归一化为分类概率, 查询样本属于第 c 类的概率为

$$Pr(y = c | \mathbf{x}_q) = \frac{\exp(-d(\mathbf{f}_\phi(\mathbf{x}_q), \mathbf{p}_c))}{\sum_{c'} \exp(-d(\mathbf{f}_\phi(\mathbf{x}_q), \mathbf{p}_{c'}))} \quad (18)$$

式中, $\exp(\cdot)$ 表示自然指数函数, c' 表示所有类别的索引。最终使用交叉熵损失对预测结果进行监督, 定义 Prototypical Loss 为

$$L_{\text{proto}} = -\log P(y = c | \mathbf{x}_q) \quad (19)$$

3.2 Cross-Entropy Loss

交叉熵损失 (Cross-Entropy Loss) 是监督学习中常用的分类损失函数之一, 其核心思想是通过最小化预测概率分布与真实标签分布之间的差异

提升模型预测结果对真实标签的拟合能力。设模型对输入样本 x 的预测类别概率为

$$Pr(y = c|x) = \frac{\exp(f_c(x))}{\sum_{c'=1}^C \exp(f_{c'}(x))} \quad (20)$$

式中, $f_c(x)$ 表示模型输出的logits向量, $f(x) = [f_1(x), f_2(x), \dots, f_C(x)]^T$ 中的第 c 个分量,即第 c 个类别的得分,且 $c \in \{1, \dots, C\}$,表示特定的索引。对应的交叉熵损失函数定义为

$$\mathcal{L}_{ce} = -\log P(y = c|x) \quad (21)$$

基于两者的复合损失函数PCE Loss,定义为

$$\mathcal{L}_{total} = \alpha \cdot \mathcal{L}_{prototypical} + (1 - \alpha) \cdot \mathcal{L}_{ce} \quad (22)$$

式中,超参数 $\alpha \in [0, 1]$,为权重系数,用于平衡两种损失在训练过程中的贡献,本文在 $\alpha \in [0, 1]$ 范围内进行搜索,结果表明 $\alpha = 0.5$ 时模型精度最优,故后续实验均固定 $\alpha = 0.5$,复合损失如图4所示。




图4 复合损失结构图




图5 无人机时频图

Prototypical Loss强调样本在特征空间中向类别中心聚合,提升类内一致性;而CrossEntropy Loss则优化决策边界,提高类别区分能力。两者联合优化,有助于在小样本条件下构建既稳定又具备判别性的特征表示,从而提升整体分类性能。

4 实测数据和结果分析

4.1 数据集构成

DIAT- μ SAT^[16]数据集由印度浦那国防高级技术研究所(Defence Institute of Advanced Technology, DIAT)开发,图5展示了该数据集中6种不同无人机的时频图像。该数据集采用X波段连续波雷达采集,专用于低空小型空中目标的检测与分类,包含6类目标,总计4 849张微多普勒图像,微多普勒采样频率为10 kHz,每次实验持续3 s,离散傅里叶变换(DFT)变换点数为1 024。在进行短时傅里叶变换(STFT)时,选用汉明窗,窗长设置为256个采样点(对应25.6 ms),相邻窗口之间重叠200个采样点(约占78.1%,即20.0 ms)。该数据集采集于真实室外场景,未在消声室或模拟背景下进行采集,背景中自然包含由姿态变化、多视角采集和多目标同时运行引起的信号叠加与多路径效应等干扰成分。

4.2 实验设置

本文所有实验均在 Pytorch 框架下进行,处理器为 Intel (R) Xeon (R) Gold 6132 CPU, 并利用 NVIDIA GeForce RTX 3090 显卡加速训练。首先将数据集划分为两部分,其中3个类别用于训练,另外3个完全不重叠的类别用于测试,所有实验均围绕上述数据集上的 C -way K -shot 分类任务展开,其中 C 表示每个小样本学习任务 (episode) 中的类别数量, K 表示每类的支持图像数量。具体而言,将在上述数据集上进行 3-way 1-shot 和 3-way 5-shot 分类任务。本文采用 episode 训练机制^[17],即采用小样本任务训练 (episodic training) 和测试 (episodic evaluation) 策略进行训练与测试。每个 episode 中,除了每个类别的 K 张支持图像,还会从每个类别中选择 15 张查询图像,例如在进行 3-way 1-shot 任务时,1 个 episode 包含 3 张支持图像和 45 张查询图像。训练时所有谱图均先缩放再裁剪至 224×224 ,采用数据增强和正则化策略,通过随机调整亮度、对比度、饱和度、随机翻转减少过拟合带来的影响。鉴于小样本学习任务对样本数量的敏感性以及在未见类别上评估泛化能力的特殊性,本文从训练集中每类随机选取 80 张图像构建训练任务池,从测试集中每类随机选取 20 张图像构建测试任务池,训练阶段构建 10 000 个 episodes,每个 episode 的批大小 (Batchsize) 设置为 1,初始学习率设为 5×10^{-4} ,使用 Adam 优化算法,测试阶段构建 500 个 episodes,以所有 episodes 的 top-1 平均准确率为评估标准。

4.3 实验结果分析

4.3.1 特征可视化分析

为深入分析模型在小样本学习任务中对无人机的分类能力与特征区分表现,本文进行了测试阶段的混淆矩阵特征可视化,如图6所示。

结果显示,在 5-shot 设置下,模型对 3 类目标的识别准确率均超过 91%,分别为 91.39%、92.29% 和 92.60%,表现出较强的判别能力。在 1-shot 设定下,模型仍然保持较高性能,准确率分别为 83.83%、84.08% 和 86.55%,但整体精度相较 5-shot

略有下降,尤其在“仿生鸟”与“双叶片旋翼和仿生鸟”之间出现了一定混淆。该现象表明,在支持样本极少情况下,模型在处理形态相似类别时的判别能力仍有限,因此增加支持样本数量有助于提升模型的鲁棒性和区分能力。





图6 混淆矩阵可视化图

4.3.2 消融实验

为验证各个模块的有效性,本文进一步针对 PCE Loss 与 EMA 模块设计了如表1所示的消融实验。

表1 消融实验

网络模型	3-way 1-shot	3-way 5-shot
	准确率	准确率
Base	72.5%	80.7%
Base+EMA	76.7%	86.9%
Base+ PCE Loss	77.8%	85.5%
Base+EMA+PCE Loss	84.1%	91.7%

如表1所示,基线模型 (Base) 采用 EfficientNet

作为特征提取骨干网络,在 1-shot 和 5-shot 分类任务下,分别达到 72.5% 与 80.7% 的准确率。在引入 PCE Loss 后,准确率分别显著提升至 77.8% 和 85.5%,这是因为该损失函数融合了原型距离监督(L_{proto})与类别判别监督(L_{ce}),在增强类内聚合性的同时,还增强了模型的类间判别能力。

此外,将 EMA 模块引入 Base 模型后,准确率分别提升至 76.7% 和 86.9%,这是因为与仅关注通道维度的 SE 相比,EMA 能同时编码通道与空间信息,并在多个感受野下进行融合,不仅有效提升了模型的判别能力,还减少了约 3×10^5 个参数量,实现了轻量化与特征表达能力的有效平衡。

当 PCE Loss 与 EMA 联合使用时,模型在两个设置下均取得最优性能(84.1% 和 91.7%),验证了两者在小样本学习任务中的协同增益效果。

4.3.3 不同网络对比结果分析

为验证本文方法在小样本无人机数据场景下的优越性,本文使用同样的数据集,相同的训练策略和分类方法,对不同特征提取网络进行了对比实验。为保证对比的公平性,除本文网络外,所有对比网络(Resnet50、VisionTransformer、EfficientNetV2)均分别在标准交叉熵损失与本文提出的 PCE Loss 两种配置下进行训练与测试,并取两者中 top-1 平均准确率较高的一组作为该网络最终性能表现。对比结果如表 2 所示。

表 2 不同网络对比实验

网络模型	参数量	FLOPs	准确率	
			3-way 1-shot	3-way 5-shot
Resnet50 ^[18]	2.35×10^7	4.13×10^9	76.5%	82.6%
VisionTransformer ^[19]	8.58×10^7	16.8×10^{10}	82.6%	86.5%
EfficientNetV2 ^[20]	1.98×10^7	2.87×10^9	71.6%	81.2%
本文网络	3.7×10^6	8.8×10^8	84.1%	91.7%

从不同网络对比的实验结果可以看出,相对于 Resnet50、VisionTransformer 和 EfficientNetV2 模型,本文模型在参数量仅为 3.7×10^6 、浮点运算量(FLOPs)为 8.8×10^8 的情况下,分别在 1-shot 和 5-shot 任务中实现了 84.1% 与 91.7% 的准确率,显著优于其他主流模型。

与 ResNet50 相比,本文模型参数量和计算量

分别降低了约 84.3% 和 78.7%,但在准确率上分别提升了 7.6%(1-shot)和 9.1%(5-shot);而与轻量级的 EfficientNetV2 相比,本文模型的参数量进一步减少 81.3%,FLOPs 降低 69.3%,准确率则分别提升了 12.5% 和 10.5%。尽管 VisionTransformer 在准确率方面略高于 ResNet50,但其模型参数高达 8.58×10^7 ,FLOPs 达到 1.68×10^{10} ,远高于其他模型,部署成本较高。此外,由于其对大规模训练数据的依赖性较强,在小样本场景下存在一定的限制性。

综上所述,本文所提出的模型在保持较低参数复杂度和计算成本的同时,还兼顾了优异的小样本无人机数据识别性能。

4.3.4 不同方法对比结果分析

为验证本文方法在小样本分类任务中的性能优势,本文在相同的数据集与小样本学习设置下,选取原型网络(Prototypical Network)^[15]和匹配网络(Matching Networks)^[21]作为对比实验的基准模型。Matching Network 基于度量学习思想,通过计算支持集与查询集图像之间的相似性进行分类;Prototypical Network 通过计算每个类别原型向量与查询样本之间的欧式距离进行分类。上述方法近年来在小样本学习领域中被广泛应用,具有较高的代表性与参考价值^[22]。对比实验结果如表 3 所示。

表 3 不同方法对比实验

实验方法	准确率	
	3-way 1-shot	3-way 5-shot
Matching Network	76.5%	82.7%
Prototypical Network	80.4%	87.9%
本文方法	84.1%	91.7%

在 1-shot 和 5-shot 设置下,本文方法分别达到 84.1% 和 91.7% 的分类准确率,相比 Matching Network 和 Prototypical Network 均有显著提升。相较于两种方法所采用的全局特征表示与匹配策略,本文基于多尺度局部特征匹配的方法在特征表示和抗混淆性方面表现出了更强的性能优势,尤其是针对如雷达多普勒图这类全局结构差异较小、判别信息主要集中于局部区域的任务场景。对比结果表明,在同等小样本学习设置下,本文方法具备更强的特征表达能力与类间区分能力,能够

在不同支持样本数量的情景下保持良好的分类效果。

5 结束语

本文提出了一种基于多尺度特征增强与度量学习的雷达无人机识别方法 EMLNet, 显著提升了小样本场景下的无人机识别性能。该方法以轻量化的 EfficientNet 为主干网络, 引入 EMA 注意力机制, 通过多尺度并行结构与跨空间依赖建模, 有效提升了对多普勒图像的特征表达能力。同时, 引入了局部特征匹配策略, 实现了对支持集与查询集之间的细粒度相似性建模。为提升训练稳定性和模型泛化能力, 所提方法进一步设计了 PCE Loss, 该损失函数融合了原型损失和交叉熵损失, 在提升类间区分性的同时增强了类内聚合性。实验结果表明, EMLNet 在小样本场景下显著提升了无人机识别的准确率, 并在参数量和计算复杂度方面相较于其他网络表现出了明显优势。

参考文献:

- [1] 李德仁, 龚江昆, 闫军, 等. 基于雷达自动目标识别技术的反无人机雷达[J]. 无线电工程, 2024, 54(4): 765-779.
- [2] 陈小龙, 袁旺, 杜晓林, 等. 多波段 FMCW 雷达低慢小探测数据集 (LSS-FMCWR-1.0) 及高分辨微动特征提取方法[J]. 雷达学报, 2024, 13(3): 539-553.
- [3] 邓振华, 陈小龙, 薛伟, 等. 海空背景下低慢小目标雷达多域多维特征建模与分析[J]. 信号处理, 2024, 40(5): 801-814.
- [4] MANDAL P, ROY L P, DAS S K. Flying Objects Classification Based on Micro-Doppler Signature Data from UAV Borne Radar[J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 1-5.
- [5] ZHAO Yichao, SU Yi. Estimation of Micro-Doppler Parameters with Combined Null Space Pursuit Methods for the Identification of LSS UAVs[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-11.
- [6] ZHANG Pengfei, YANG Le, CHEN Gao, et al. Classification of Drones Based on Micro-Doppler Signatures with Dual-Band Radar Sensors[C]//2017 Progress in Electromagnetics Research Symposium-Fall, Singapore: IEEE, 2017: 638-643.
- [7] ROJHANI N, SADEGHIBAKHI M, PASSAFIUME M, et al. Application of PCA and Unsupervised Deep Learning in Bird and Drone Discrimination Based on FMCW Radar Measurements[J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 1-5.
- [8] PARK D, LEE S, PARK S U, et al. Radar-Spectrogram-Based UAV Classification Using Convolutional Neural Networks[J]. Sensors, 2021, 21(1): 21010210.
- [9] 郇政, 周良将, 董书航, 等. 一种基于微多普勒和机器学习的无人机目标分类识别技术[J]. 雷达科学与技术, 2024, 22(5): 549-556.
- [10] ZHOU Yongjing, LI Yonggang, ZHU Weigang. A Method for Few-Shot Radar Target Recognition Based on Multimodal Feature Fusion[J]. Sensors, 2025, 25(13): 25134162.
- [11] LI Wenbin, WANG Lei, XU Jinglin, et al. Revisiting Local Descriptor Based Image-to-Class Measure for Few-Shot Learning[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA: IEEE, 2019: 7260-7268.
- [12] LIU Qifan, CAO Wenming, HE Zhihai. Cycle Optimization Metric Learning for Few-Shot Classification[J]. Pattern Recognition, 2023, 139: 109468.
- [13] TAN Mingxing, LE Q V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks[C]//International Conference on Machine Learning, Long Beach, CA, USA: PMLR, 2019: 6105-6114.
- [14] OUYANG Daliang, HE Su, ZHANG Guozhong, et al. Efficient Multi-Scale Attention Module with Cross-Spatial Learning[C]//2023 IEEE International Conference on Acoustics, Speech and Signal Processing, Rhodes Island, Greece: IEEE, 2023: 1-5.
- [15] SNELL J, SWERSKY K, ZEMEL R. Prototypical Networks for Few-Shot Learning[C]//the 31st International Conference on Neural Information Processing Systems, Long Beach, CA, USA: NIPS, 2017: 4080-4090.
- [16] KUMAWAT H C, CHAKRABORTY M, RAJ A A B, et al. DIAT- μ SAT: Small Aerial Targets' Micro-Doppler Signatures and Their Classification Using CNN[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 1-5.
- [17] GHAROUN H, MOMENIFAR F, CHEN Fang, et al. Meta-Learning Approaches for Few-Shot Learning: A Survey of Recent Advances[J]. ACM Computing Surveys, 2024, 56(12): 1-41.
- [18] HE Kaiming, ZHANG Xiangyu, REN (下转第93页)

融合光学信息的阵列干涉 SAR 三维成像

张月皎^{1,2,3}, 焦泽坤^{1,2}, 李若明^{1,2}

(1. 中国科学院空天信息创新研究院, 北京 100190; 2. 微波成像技术国家重点实验室, 北京 100190;
3. 中国科学院大学电子电气与通信工程学院, 北京 100194)

摘要: 合成孔径雷达(SAR)三维成像技术具备高度向的分辨能力,能够有效解决二维SAR成像中的叠掩问题。然而,现有技术的数据获取方面存在周期较长、成本较高等问题,同时,重建结果易受噪声干扰,导致异常值的出现。针对这些挑战,本文提出了一种融合光学信息的阵列干涉SAR三维成像方法。该方法通过引入光学图像提供的先验几何信息,对SAR三维重建过程进行约束,从而拓展了数据源,降低了SAR数据获取成本,并有效地纠正了异常值。具体而言,该方法首先进行初步的三维成像,并利用初始的三维点云建立起光学图像与SAR图像之间的配准关系;接着,对光学图像进行几何结构分割,并将分割结果作为约束条件应用于SAR三维重建过程中,最终得到基于几何约束的三维重建结果。通过实测数据进行验证,结果表明该方法显著抑制了三维重建中的离群散射点,获得了同时包含光学纹理和SAR纹理的高质量三维点云,有望解决光学和SAR二维图像融合面临的异质性难题,为后续基于融合图像的目标解译奠定基础。

关键词: 三维成像; 二维映射; 图像配准; 几何约束

中图分类号: TN957.52

文献标志码: A

文章编号: 1672-2337(2026)01-0083-11

引用格式: 张月皎, 焦泽坤, 李若明. 融合光学信息的阵列干涉 SAR 三维成像[J]. 雷达科学与技术, 2026, 24(1): 83-93.

ZHANG Yuejiao, JIAO Zekun, LI Ruoming. 3D Imaging of Array Interferometric SAR with Integrated Optical Information[J]. Radar Science and Technology, 2026, 24(1): 83-93.

3D Imaging of Array Interferometric SAR with Integrated Optical Information

ZHANG Yuejiao^{1,2,3}, JIAO Zekun^{1,2}, LI Ruoming^{1,2}

(1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100190, China;
2. National Key Laboratory of Microwave Imaging Technology, Beijing 100190, China;
3. School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100194, China)

Abstract: Synthetic aperture radar (SAR) three-dimensional (3D) imaging technology provides vertical resolution and effectively addresses the issue of image stacking in SAR imaging. However, existing technologies face challenges, including long data acquisition periods and high costs, and the reconstruction results are prone to noise interference, which may lead to the presence of outliers. To overcome these limitations, a novel method that integrates optical information with array interferometric SAR (array-InSAR) for 3D imaging is proposed in this paper. The proposed method incorporates the prior geometric information from optical images to constrain the SAR 3D reconstruction process, thereby expanding the data sources, reducing the cost of SAR data acquisition, and effectively correcting outliers. Specifically, the method first performs an initial 3D imaging process and establishes the registration relationship between the optical and SAR images using the initial 3D point cloud. The optical image is then segmented based on its geometric structure, and the segmentation results are applied as a constraint during the SAR reconstruction. Finally, the 3D reconstruction results, constrained by geometric information, are obtained. The validation using the measured data demonstrates that the proposed method significantly reduces outlier scatter points in the 3D reconstruction, resulting in high-quality 3D point clouds that simultaneously incorporate optical and SAR textures. This approach shows promise in addressing the challenges of heterogeneity encountered in the fusion of optical and SAR two-dimensional (2D) images, providing a solid foundation for subsequent target interpretation based on the fused images.

Key words: three-dimensional (3D) imaging; two-dimensional (2D) mapping; image registration; geometric constraints

0 引言

微波成像是高分辨率对地观测的重要手段,具有全天时、全天候的优势,在军事侦察、地形测绘、环境监测、地质勘探和灾情调查等方面具有重大应用价值。合成孔径雷达(Synthetic Aperture Radar, SAR)成像技术在距离向通过发射大带宽信号并结合匹配滤波技术实现距离维分辨,在方位向构建合成孔径实现方位维分辨^[1-3]。但SAR图像仅具有二维分辨能力,是目标三维结构在距离多普勒平面的投影,在城区等立体结构复杂的区域,容易产生严重混叠,限制了SAR图像的应用效能^[4]。SAR三维成像能够重建目标电磁散射特性在三维空间的分布,有效解决二维SAR图像中的叠掩问题,提升目标识别和解译能力,在三维测绘、形变监测、反恐作战和灾害评估等方面发挥了重要作用,受到国内外研究机构的广泛关注^[5-7]。

目前,基于SAR的三维成像技术,主要以德国宇航中心(DLR)提出的层析SAR(Tomography SAR, TomoSAR)技术为代表,依靠多次重复观测获得目标高程向观测信息,进而实现三维重建。在高程向信息获取方面,主要有多航过和阵列干涉两种体制。德宇航利用TerraSAR-X的多航过数据进行了大量关于SAR三维重建的研究^[8-10];中国科学院空天信息创新研究院发布的SAR-MV3D Imaging数据集中包含多个地区的阵列干涉SAR数据^[11],国内外学者也利用该数据集进行了大量的相关研究^[12-14]。本文主要关注阵列干涉SAR的相关研究情况。在成像算法方面,传统的TomoSAR高程向反演算法主要是基于谱估计的三维成像算法,包括Capon空间谱估计算法^[15]、多重信号分类算法(Multiple Signal Classification, MUSIC)^[16-17]等;近年来,随着朱晓香教授等首次将压缩感知^[18-19]技术应用于SAR三维重建中,基于压缩感知的SAR三维重建理论和算法的研究也取得了一系列成果,在一定程度上解决了TomoSAR高度向分辨率低以及所需观测数量多等问题。但受限于处理方法,即便是基于稀疏信号处理的成像方法,仍然需要至少十余次的重复观测,这将导致数据获取周期长且成本较高;而在较少观测次数条件下,三维

成像性能急剧下降,且由于噪声的干扰,重建结果会有异常值的出现。提升成像质量与降低观测成本两种需求形成难以调和的矛盾,这就需要拓展三维成像信息来源,实现高效能低成本的三维成像。


为获取更多有用信息,一些研究者尝试深入挖掘成像场景的先验信息。例如,采用联合稀疏模型^[20]、非邻域模型^[21]以及马尔可夫随机模型^[22]等方法,获取SAR图像像素邻域关系,试图提升三维成像效果。另一方面,由于可见光图像有丰富的细节和纹理信息,一些学者试图将光学图像与SAR影像进行融合^[23],进一步提高信息维度。

针对上述背景,本文提出一种融合光学特征的阵列干涉SAR三维成像方法,以阵列干涉SAR三维点云为桥梁,实现SAR和光学图像的配准,并将配准结果融合应用于阵列干涉SAR的三维成像当中,主要体现在利用光学图像几何结构信息约束SAR的三维成像,在提升阵列干涉SAR三维成像精度的同时,能够获得同时包含光学和SAR图像纹理的三维点云。


1 阵列干涉SAR三维成像

机载阵列干涉SAR三维成像几何示意图如图1(a)所示,假设雷达沿 x 方向做匀速直线运动,则 a 为方位向, r 为斜距向, s 为高程向。 $P_0, P_1, \dots, P_{M-1}$ 为 M 个天线阵列,沿交轨向布设。

对于某一天线 P_m ,其方位向和距离向(斜距向)的二维成像采用常规的SAR成像算法。在高程向,如图1(b)所示,单个方位-斜距分辨率单元



(a) 阵列干涉SAR三维成像几何坐标示意图



光学图像和 SAR 图像形成过程中,由于两种传感器采集图像时完全不同的成像机制,导致两




图2 融合光学信息的SAR三维成像方法

种类型图像之间存在差异,匹配难度较大^[26-27]。首先,相对于光学图像,SAR图像存在相干斑噪声,不仅降低了空间分辨率,还严重影响了图像质量和其他定量信息的提取。其次,光学成像和SAR成像的辐射特性不同。即使是相同的特征对象,也可能表现不同的灰度特征。最后,光学成像和SAR成像的几何特征不同。SAR系统采用侧视成像,使得SAR图像会出现一些固有的特性,如叠掩、阴影、透视收缩等,这些几何形变也增加了配准的难度。

传统的光学图像和SAR图像的配准技术大致可以分为两类:基于区域的配准方法^[28]和基于特征的配准方法^[29]。近年来,随着深度学习技术的发展,研究人员开始探索将深度学习框架应用于光学与SAR图像的配准^[30-31]。现有方法主要基于图像纹理及结构特征。在城市建筑密集区及山区等地形起伏较大区域,两种图像在结构和辐射特性上存在显著差异,难以实现高质量配准。

本文提出的研究方法如下:首先,采用压缩感知算法对多通道二维SAR图像进行三维成像,生成初始的三维点云。接着,基于光学相机成像原理,对初始三维点云进行映射。这一过程相当于通过虚拟相机对三维点云进行“拍摄”,其中,虚拟相机的位置信息和姿态被设置为与实际光学图像采集时相机的位置和姿态一致。通过这一映射,获得的二维图像称为点云二维图像。在此过程

中,点云二维图像在几何特征上与实际光学图像具有高度相似性。最后,对点云二维图像与光学图像进行精确配准,并将配准结果反向映射到二维SAR图像中。通过这一系列步骤,三维点云作为桥梁,建立起了光学图像与多通道二维SAR图像之间的对应关系。所采用的方法框架如图2(b)所示。

三维点到二维像素的映射机制为

$$Z_c \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & 0 \\ 0 & f_y & 0 \\ 0 & 0 & 1 \end{bmatrix} [R \quad T]_{3 \times 4} \begin{bmatrix} x_w \\ y_w \\ z_w \\ 1 \end{bmatrix} \quad (4)$$

式中, (x_w, y_w, z_w) 为某一点的世界坐标, $[R \quad T]$ 为相机的外参矩阵,它定义了相机相对于世界坐标系

的位置和姿态, $\begin{bmatrix} f_x & 0 & 0 \\ 0 & f_y & 0 \\ 0 & 0 & 1 \end{bmatrix}$ 为相机的内参矩阵, $f_x =$

$\frac{f}{dx}, f_y = \frac{f}{dy}, f$ 为焦距, dx, dy 表示像素物理尺寸,

(u, v) 为点云二维图像的像素坐标。在本方法中,三维点云中的每个点通过该投影模型转换为二维平面上的对应点,从而实现三维场景的二维表示。这一过程模拟了实际相机捕捉图像时的成像机制,确保了三维信息的准确转换,并为后续的图像配准提供了几何基础。

图2(b)同时也展示了光学图像与点云二维图像的配准过程。本文采用的配准方法为基于强度

的多模态图像配准技术。具体配准过程如下:首先,读取待配准的图像,并进行必要的预处理,包括去噪、对比度增强等,以提高图像质量;接着,选择梯度下降作为优化算法、互信息作为相似度量标准、相似变换作为变换模型,并进行相关参数配置;之后,计算初始变换参数并进入迭代过程。在每次迭代中,首先根据当前的变换参数对移动图像进行变换,随后计算变换后的图像与固定图像之间的相似度量。根据计算得到的相似度量结果,调整变换参数。参数调整后,判断是否满足收敛条件,常见的收敛条件包括连续若干次迭代后相似度量变化小于预设阈值,或达到设定的最大迭代次数。若未满足收敛条件,则继续迭代;若满足收敛条件,则输出最终的变换参数及配准后的移动图像。

2.2 基于光学图像几何约束的 SAR 三维成像

2.2.1 光学图像几何结构分割

由于本文研究目标为建筑物,而建筑物通常具有规则的几何结构,因此在几何结构提取中,采用了边缘检测与形态学腐蚀膨胀相结合的方法。这种方法能够有效地提取出建筑物的轮廓和边界,适用于具有规则形态的目标区域。边缘检测用于初步提取图像边缘信息,形态学操作进一步细化和增强几何特征,从而提高分割准确性。具体分割流程如图 2(c)所示。

边缘检测旨在寻找图像中像素强度急剧变化的位置,数学上可通过求导数体现。以拉普拉斯算子为例,它是二阶导数算子,用于衡量函数的二阶变化率。将图像像素强度视为二维函数 $I(x,y)$,拉普拉斯算子的表达式为

$$\nabla^2 I = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (5)$$

其离散近似形式为

$$\nabla^2 I(x,y) = I(x+1,y) + I(x-1,y) + I(x,y+1) + I(x,y-1) - 4I(x,y) \quad (6)$$

该操作通过计算当前像素及其邻域像素的强度差异,捕捉建筑物轮廓信息。当该值较大时,表明该像素点周围强度变化剧烈,可能为边缘位置。

对于具有规则几何形状(如直线、矩形、角落等)的建筑物,边缘检测可为后续结构提取提供初步参考信息。

接着,通过形态学操作优化边缘信息。在提取建筑物几何结构时,腐蚀操作去除噪声并消除小裂缝,使轮廓更平滑连贯;膨胀操作则恢复被腐蚀去除部分的结构,增强边界特征。对于灰度图像 $f(x,y)$ 和结构元素 $b(x,y)$,腐蚀后的图像 $g(x,y)$ 定义为

$$g(x,y) = \min \{ f(x+s,y+t) - b(s,t) | (s,t) \in D_b \} \quad (7)$$

膨胀后的图像 $h(x,y)$ 定义为

$$h(x,y) = \max \{ f(x-s,y-t) + b(s,t) | (s,t) \in D_b \} \quad (8)$$

式中, D_b 是结构元素 b 的定义域。腐蚀与膨胀的结合可有效改善边缘提取的质量、去除噪声并保持建筑物结构的完整性。

霍夫变换将边缘图像点集转换至参数空间,以检测直线,能准确提取建筑物直线边界,消除噪声和不连续性误差。霍夫变换后通过合并参数差异小的直线,进一步简化结果并提高几何结构的准确性。

通过上述操作,可提取出建筑物清晰的几何边界,得到精确几何结构分割结果,为后续基于几何约束的三维成像奠定基础。

2.2.2 基于几何约束的阵列干涉 SAR 三维成像


基于几何约束的 SAR 三维成像主要处理流程如图 2(d)所示。该处理流程的具体步骤如下:

步骤 1:首先,采用传统的 SAR 成像方法对目标进行初步的三维成像,以得到目标的初始三维结构。此步骤通过传统压缩感知算法对目标进行粗略重建,为后续的几何约束处理提供基础。

步骤 2:基于已获取的几何结构信息,对初始三维成像结果中每个几何区域内的点云数据进行三维平面拟合。具体来说,如图 3 所示为从两个不同角度展示的三维点云平面拟合示意图,图中的蓝色点表示通过传统压缩感知算法获得的三维点云,而红色面表示对这些点进行三维平面拟合后的结果。该平面的数学表达式为

$$s = A_{\text{fit}} \cdot a + B_{\text{fit}} \cdot r + K_{\text{fit}} \quad (9)$$

式中, $A_{\text{fit}}, B_{\text{fit}}, K_{\text{fit}}$ 为经过变换之后的平面参数, a 和 r 分别表示方位向和斜距向坐标。



(a) 角度1 (b) 角度2

图3 三维点云平面拟合示意图

步骤3: 在目标区域内进行进一步的三维成像。以某一方位-斜距像素单元 (a_i, r_j) 为例, 在成像过程中, 判断该像素是否位于已识别的几何结构区域内。如果该像素不属于任何几何结构区域, 则仍采用传统的压缩感知方法进行三维反演; 如果该像素位于几何结构区域内, 则对其三维反演过程施加几何约束。具体约束规则如下:

首先进行理想参考位置计算。假设步骤2中得到的拟合平面表示该点的理想位置, 则可以通过下式计算该像素单元的参考高度:

$$S_{\text{ref}} = A_{\text{fit}} \cdot a_i + B_{\text{fit}} \cdot r_j + K_{\text{fit}} \quad (10)$$

然后进行信噪比判断和约束范围计算。对于像素单元 (a_i, r_j) , 计算二维SAR图像中该像素单元的信噪比 SNR_{ij} 。设定一个信噪比阈值 SNR_0 , 若 $SNR_{ij} \geq SNR_0$ (即信噪比较高, 图像质量较好)。则重建的约束范围可以通过信噪比与某一约束参数 λ 的乘积来确定。具体表示为

$$S_{\text{ref}} \pm \frac{1}{2} \cdot SNR_{ij} \cdot \lambda \quad (11)$$

相应的约束条件可以表示为

$$S_{\text{ref}} - \frac{1}{2} \cdot SNR_{ij} \cdot \lambda < s_{ij} < S_{\text{ref}} + \frac{1}{2} \cdot SNR_{ij} \cdot \lambda \quad (12)$$

式中, λ 是一个常数或可调参数, 用来表征约束强度。在此情况下, 由于高信噪比区域表示图像质量较高, 因此可以对该区域进行更精确的三维重建, 此时较宽的约束范围有助于利用高质量的数据信息, 从而确保更好的重建效果。

当信噪比较低时, 即 $SNR_{ij} < SNR_0$, 表明图像质量较差, 可能存在较多噪声。在这种情况下, 复杂的三维重建过程容易受到噪声的显著影响, 进而严重影响重建结果的精度。因此, 在低信噪比

区域, 重建结果将直接被约束到拟合结果的参考值, 即采用已有的拟合结果作为重建的结果, 以避免噪声影响造成不准确的重建, 该约束条件可以表示为

$$s_{ij} = S_{\text{ref}} \quad (13)$$

综上所述, 基于几何约束的三维反演问题可以由如下数学表达式描述:

$$\hat{\gamma} = \arg \min_{\gamma} \|R\gamma - g\|_2^2 \quad \text{subject to} \quad \text{supp}(\gamma) \subseteq [S_{\text{ref}} - L/2, S_{\text{ref}} + L/2] \quad (14)$$

式中, $\text{supp}(\gamma)$ 表示 γ 的非零元素的索引集, L 表示约束范围的长度, 具体表达式如下:

$$L = \begin{cases} SNR_{ij} \cdot \lambda, & SNR_{ij} \geq SNR_0 \\ 0, & SNR_{ij} < SNR_0 \end{cases} \quad (15)$$

本节描述了基于几何约束的SAR三维成像处理流程和数学模型, 综合考虑了不同信噪比区域的特性以及几何结构的信息, 旨在提高SAR三维成像的精度和可靠性, 尤其在复杂目标区域和噪声干扰的情况下, 能够实现更具针对性且有效的三维重建。

2.3 光学纹理信息引入

在光学图像与点云二维图像进行配准后, 二者的像素之间建立起了一一对应的关系。点云二维图像由SAR三维点云通过映射获得, 因此光学图像的像素与SAR三维点云之间存在明确的对应关系。基于此, 可以将光学图像像素的色彩信息赋予与之对应的SAR三维点云。这样, SAR点云不仅保留了原有的强度信息, 同时也获得了来自光学图像的色彩和纹理信息。

以光学图像中某一像素为例分析, 假设该像素为 $a_i(x_i, y_i, \text{rgb}_i)$, 其中 x_i, y_i 为该像素的二维坐标, rgb_i 为 3×1 的向量, 表示光学像素的RGB值。假设经配准后, 点云二维图像中与光学图像像素 a_i 对应的像素为 $b_j(x_j, y_j)$, 其中 x_j, y_j 为该像素的二维坐标。由于点云二维图像是基于SAR三维点云生成的, 因此针对像素 $b_j(x_j, y_j)$, 可以根据几何关系找到其在SAR三维点云中对应的散射点 $s_i(\text{rg}_i, \text{az}_i, h_i, \text{rcs}_i)$, 其中 rg_i 代表散射点 s_i 在SAR图像中的距离向像素坐标, az_i 代表散射点 s_i 在SAR

图像中的方位向像素坐标, h_i 为散射点 s_i 的高度, rcs_i 为散射点 s_i 的复散射系数, 包含散射系数的幅度和相位。通过上述几何关系可以建立起光学图像像素 $a_i(x_i, y_i, \mathbf{rgb}_i)$ 与 SAR 三维点云中散射点 $s_i(rg_i, az_i, h_i, rcs_i)$ 之间的对应关系, 从而得到扩展后的散射点表示 $s_i(rg_i, az_i, h_i, rcs_i, \mathbf{rgb}_i)$ 。此时, 三维点云中散射点不仅包含 SAR 图像的散射信息, 还结合了光学图像的色彩信息, 形成了多模态数据的综合表示。

3 实验结果与分析

为验证本文提出方法的有效性, 本节选用中国科学院空天信息创新研究院发布的机载阵列干涉 SAR 微波视觉三维成像数据集^[11], 进行阵列干涉 SAR 三维成像实验, 该数据集的相关参数如表 1 所示, Google Earth 光学图像如图 4 所示。数据集由 8 景 SAR 图像组成。

表 1 实验数据集雷达系统参数

参数	参数值
带宽	500 MHz
阵列模式	1 发 8 收
图像像素点数	1 220×3 100
像素单元尺寸	0.149 9 m×0.073 4 m
成像场景海拔高度	595 m
机载平台高度	1 668 m



图 4 实验数据集 Google Earth 光学图像

3.1 光学图像与 SAR 图像配准实验


为方便分析, 选取图 4 红框中的两栋大楼作为实验对象进行分析, 选取目标的光学图像和对应的 SAR 二维图像如图 5(a)、(b) 所示。其中, 由于缺乏真实完整的目标光学图像, 这里利用软件

Blender 中相机工具对目标场景的倾斜摄影模型进行“拍照”获得光学图像, 在后续实验中, 仅用到该二维光学图像, 并未用到其中的三维信息, 光学图像尺寸为 2 160×1 080 像素。


首先, 采用压缩感知算法对目标区域进行初始 SAR 三维成像, 获取目标初始三维点云, 如图 5(c) 所示。然后, 采用本文 2.1 中提出的三维点云映射方法对初始三维点云进行二维映射, 获得相应的点云二维图像, 其图像尺寸为 2 160×1 080 像素, 如图 5(d) 所示。对比图 5(c) 与图 5(d), 二者在点云保留的完整性、三维结构的完整性和准确性、空间关系的一致性以及视觉的可读性等方面, 都有较好的一致性, 证明了二维映射的有效性。




(a) 实验对象光学图像



(b) 实验对象 SAR 图像



(c) 实验对象初始三维点云



(d) 实验对象点云二维图像

图 5 实验对象各场景图像

采用2.1节提到的基于强度的多模态图像配准方法进行点云二维图像和光学图像的配准,配准结果的棋盘格融合图如图6(a)所示。为了进一步展示配准的精度,图6中展示(b)、(c)两个子图,分别放大了建筑物边缘和中间具有明显强弱反射区域的配准效果。通过放大后的细节图可以清晰地看到,无论是建筑物整体的吻合程度,还是建筑的边界区域,以及中间强弱反射的位置(包括窗户的位置),都表现出较高的一致性。这表明所采用的配准方法能够有效地保留图像中的精细特征。



(a) 配准结果整体展示



(b) 区域1放大展示

(c) 区域2放大展示

图6 光学图像与点云二维图像配准结果

3.2 基于光学几何结构约束的SAR三维成像实验

本节首先对图6所示配准以后的光学图像进

行几何结构分割,采用2.2.1节中提到的边缘检测和腐蚀膨胀相结合的方法,对目标立面进行几何结构的分割。分割结果如图7所示。图中绿色的边缘是提取出的建筑物几何边界,相邻两条边缘之间的部分可以认为在同一平面上。



图7 光学图像几何结构分割结果

选取图7中红色矩形框中的 200×100 像素区域进行基于几何结构约束的三维成像,并进行分析。约束强度 λ 取不同的值时,三维重建结果如图8(a)、(b)、(c)、(d)所示,假设将数据集^[11]中的激光点云结果作为验证的参照,分别统计了约束强度 λ 取不同值时重建结果的各三维点到实际位置的距离,得到其直方图分布,并对分布进行了拟合,如图8(e)、(f)、(g)、(h)所示,其横坐标代表重建点到真实点之间的距离,左侧纵坐标表示点的数量,右侧纵坐标表示拟合之后的归一化概率密度。表2为约束强度 λ 取不同的值时,各三维点到实际位置距离的均值、标准差和均方差。




图8 不同约束强度下的重建结果和三维点的分布情况

从重建结果来看,当 λ 值较小,即约束强度较大时,约束条件更加严格,重建结果会趋向于某个目标平面(如地面、墙面等)。这种情况下,三维点


云会更紧密地接近目标平面,噪声和杂散点被有效约束在目标平面附近,能减少误差和异常值,从而提高整体重建结果的稳健性。但当 λ 值过小,即

表 2 不同约束强度下的重建结果统计参数


约束条件	均值	标准差	均方差
未约束	4.66	15.9	274.26
$\lambda = 1$	0.72	0.80	1.16
$\lambda = 0.5$	0.68	0.66	0.90
$\lambda = 0.1$	0.32	0.24	0.16

约束过强时,虽然整体平面拟合效果很好,但细节信息(例如窗户的反射特征、建筑表面的微小起伏等)会被抑制。在这种情况下,由于所有点都强制接近目标几何结构,甚至一些原本应有的细节特征可能会丧失或变得模糊,导致重建结果无法真实地反映物体表面的复杂结构。相对而言,较大的 λ 值会放宽约束条件,使得点云更自由地分布,可能会更好地保留细节信息,如建筑物的窗户等特征,尤其在复杂的环境中,能够捕捉到更多的微小变化。因此,约束强度 λ 的选择需要谨慎平衡,折中选择。

最后,选取 $\lambda = 0.5$,对目标区域整体进行约束成像,成像结果如图 9(a)所示。将光学图像纹理按照像素对应关系映射到三维点云中,结果如图 9(b)所示。就得到了同时拥有光学纹理和 SAR 纹理的三维点云,初步实现了 SAR 图像和光学图像的互补特性融合,可有效提升遥感图像判读和解译的准确性。



(a) SAR 三维点云



(b) 具有光学纹理三维点云

图 9 几何约束后的三维点云及光学纹理渲染结果

本节对文中提出的方法进行了实验验证,结果较为理想。然而,在实际应用中仍可能遇到一

些问题。例如,在数据获取过程中,若视角设置不当,出现的透视收缩和顶底位移等现象可能会导致获得的二维 SAR 图像楼体有效散射点减少,这会导致重建的三维点云较为稀疏,进而影响后续光学图像与 SAR 图像的配准精度。此外,入射角的变化会影响雷达等效基线长度,从而对高度维分辨率产生影响。因此,在数据获取过程中,需要综合考虑有效散射点数量与高度维分辨率,合理调整观测视角,以最大程度地获取完整的楼面信息,并保证较高的第三维分辨率。

4 结束语

本文针对 SAR 的三维成像提出了一种新的光学图像与 SAR 图像的配准框架,并利用光学图像为 SAR 的三维成像提供先验信息,有效提高了三维重建的精度。本文的工作为光学图像与 SAR 图像的融合提供了新的思路,并为后续基于融合图像的目标解译奠定了基础。

然而,本文仅从光学图像中提取了竖直边缘信息作为几何结构约束,忽略了图像中可能存在的其他角度的信息(例如水平纹理等)。这些信息对于提升重建精度和改善点云质量具有潜在的价值。因此,未来的研究将进一步扩展光学图像中几何信息的提取方式,综合考虑多角度纹理信息,以进一步优化该方法的性能。

参考文献:

- [1] CUMMING L G, WONG F H. 合成孔径雷达成像——算法与实现[M]. 洪文,等译. 北京:电子工业出版社,2012.
- [2] 胡泽宾. SAR 干扰技术综述[J]. 雷达科学与技术,2024, 22(4):369-376.
- [3] 吕泽鑫,仇晓兰,丁赤飏. 无人机载 PolInSAR 城区散射机制初步分析[J]. 雷达科学与技术,2022,20(5):475-479.
- [4] REN Zishuai, JIANG Zheyi, GUO Rui, et al. Applying the Cylindrical Wave Model with Height Thresholding to Airborne SAR Tomography [C]//2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece: IEEE, 2024:2399-2402.
- [5] TIAN H, DONG Chunzhu, YIN Hongcheng, et al. Airborne Sparse Flight Array SAR 3D Imaging Based on Compressed Sensing in Frequency Domain[J]. Journal of

- Systems Engineering and Electronics, 2023, 34(1):56-67.
- [6] 丁赤飏, 仇晓兰, 徐丰, 等. 合成孔径雷达三维成像——从层析、阵列到微波视觉[J]. 雷达学报, 2019, 8(6): 693-709.
- [7] SONG Shujie, QIU Xiaolan. A Sparse Bayesian Learning 3D Imaging Methodology Based on Polarimetric Energy Maximum in Urban Area for Pol-Array-InSAR[C]//2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece; IEEE, 2024:10777-10781.
- [8] ZHU Xiaoxiang, BAMLER R. Tomographic SAR Inversion by L_1 -Norm Regularization—The Compressive Sensing Approach[J]. IEEE Trans on Geoscience and Remote Sensing, 2010, 48(10):3839-3846.
- [9] WANG Xiao, XU Feng. Tomographic SAR Inversion by Atomic-Norm Minimization—The Gridless Compressive Sensing Approach[J]. IEEE Trans on Geoscience and Remote Sensing, 2022, 60(11):5239113.
- [10] ZHUANG Di, ZHANG Lamei, ZOU Bin. Interferometry Modeling and Height Reconstruction for High-Rise Buildings in Complex Scenes Based on One Single Interferogram[J]. IEEE Trans on Geoscience and Remote Sensing, 2024, 62(2):5206916.
- [11] 仇晓兰, 焦泽坤, 彭凌霄, 等. SARMV3D-1.0: SAR微波视觉三维成像数据集[J]. 雷达学报, 2021, 10(4):485-498.
- [12] QIU Xiaolan, JIAO Zekun, ZHANG Zhe, et al. Advances and Prospects in SAR Microwave Vision Three-Dimensional Imaging[J]. National Science Open, 2024, 3(5): 53-83.
- [13] 任子帅, 张照, 高雨欣, 等. 基于自适应高程约束的TomoSAR三维成像[J]. 雷达学报, 2023, 12(5): 1056-1068.
- [14] 姬昂, 裴昊, 张邦杰, 等. 阵列SAR高分辨三维成像与点云聚类研究[J]. 电子与信息学报, 2024, 46(5): 2087-2094.
- [15] 刘慧, 郭馨宇, 郭子夜, 等. 基于交替方向乘子法的Capon层析SAR成像方法[J]. 雷达科学与技术, 2023, 21(3):303-313.
- [16] FREY O, MEIER E. 3-D Time-Domain SAR Imaging of a Forest Using Airborne Multibaseline Data at L- and P-Bands[J]. IEEE Trans on Geoscience and Remote Sensing, 2011, 49(10):3660-3664.
- [17] MOORE T, PADEN J, LEUSCHEN C, et al. Nonparametric Array Manifold Calibration for Ice Sheet Tomography[J]. IEEE Trans on Geoscience and Remote Sensing, 2022, 60:2919-2922.
- [18] ZHU Xiaoxiang, BAMLER R. Compressive Sensing for High Resolution Differential SAR Tomography - the SLIMMER Algorithm[C]//2010 IEEE International Geoscience and Remote Sensing Symposium, Honolulu, HI, USA; IEEE, 2010:17-20.
- [19] FENG Jing, JIN Shuang, ZHANG Jinajing, et al. Three-Dimensional Initial Imaging Result of Chinese Gaofen-3 Satellite Based on CS-TomoSAR[C]//2023 IEEE Radar Conference, San Antonio, TX, USA; IEEE, 2023:1-5.
- [20] ZHU Xiaoxiang, GE Nan, SHAHZAD M. Joint Sparsity in SAR Tomography for Urban Mapping[J]. IEEE Journal of Selected Topics in Signal Processing, 2015, 9(8): 1498-1509.
- [21] SHI Yilei, ZHU Xiaoxiang, BAMLER R. Nonlocal Compressive Sensing - Based SAR Tomography [J]. IEEE Trans on Geoscience and Remote Sensing, 2019, 57(5): 3015-3024.
- [22] JIAO Zekun, DING Chibiao, QIU Xiaolan, et al. Urban 3D Imaging Using Airborne TomoSAR: Contextual Information-Based Approach in the Statistical Way [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 12:127-141.
- [23] XIANG Yuming, WANG Feng, YOU Hongjian. OS-SIFT: A Robust SIFT-Like Algorithm for High-Resolution Optical-to-SAR Image Registration in Suburban Areas[J]. IEEE Trans on Geoscience and Remote Sensing, 2018, 56(6):3078-3090.
- [24] YAN Qiancheng, JIAO Zekun, QIU Xiaolan, et al. Comparison Between Different TomoSAR Imaging Models for Airborne Platform Flying at Low Altitude [J]. Remote Sensing, 2022, 14(21):5452.
- [25] 张福博, 梁兴东, 吴一戎. 一种基于地形驻点分割的多通道SAR三维重建方法[J]. 电子与信息学报, 2015, 37(10):2287-2293.
- [26] TENG Xichao, LIU Xuecong, LI Zhang, et al. OMIRD: Orientated Modality Independent Region Descriptor for Optical-to-SAR Image Matching[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20(3):1-5.
- [27] LIN Yi, WEI Lujia, LI Lang, et al. Adaptive Multi-Scale Optical-to-SAR Image Matching[C]//2023 5th International Conference on Geoscience and Remote Sensing Mapping, Lianyungang, China; IEEE, 2023:168-171.
- [28] YE Yuanxin, SHAN Jie, BRUZZON L, et al. Robust Registration of Multimodal Remote Sensing Images Based

- on Structural Similarity [J]. IEEE Trans on Geoscience and Remote Sensing, 2017, 55 (5) : 2941 - 2958.
- [29] ZHANG Keke, YU Anxi, TONG Wenhao, et al. A Fast SAR-Optical Registration Algorithm for Land-Water Interface Area [C]//2024 9th International Conference on Signal and Image Processing, Nanjing, China: IEEE, 2024:675-679.
- [30] LIAGHAT A, HELFROUSH M S, NOROUZI J, et al. Airborne SAR to Optical Image Registration Based on SAR Georeferencing and Deep Learning Approach [J]. IEEE Sensors Journal, 2023, 23(21):26446-26458.
- [31] LIU Rui, ZHANG Hongsheng. Optical and SAR Image

Registration with Deep Reinforcement Learning [C]// 2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece: IEEE, 2024: 7375 - 7377.

作者简介:

张月皎 女,硕士研究生,主要研究方向为合成孔径雷达三维成像技术。

焦泽坤(通信作者) 男,博士,副研究员,主要研究方向为合成孔径雷达三维成像技术。

李若明 男,博士,副研究员,主要研究方向为高分辨率合成孔径雷达技术与系统。

(上接第 82 页)

- Shaoqing, et al. Deep Residual Learning for Image Recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [19] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An Image Is Worth 16x16 Words: Transformers for Image Recognition at Scale [PP/OL]. arXiv, 2020. <https://arxiv.org/html/2010.11929v2>.
- [20] TAN Mingxing, LE Q V. EfficientNetV2: Smaller Models and Faster Training [C]//Proceedings of the 38th International Conference on Machine Learning, Online: PMLR, 2021: 10096-10106.
- [21] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching Networks for One Shot Learning [C]// International Conference on Neural Information Processing Sys-

tems, Barcelona, Spain: NIPS, 2016: 3630-3638.

- [22] WU Zeng, XIAO Zhengying. Few-Shot Learning Based on Deep Learning: A Survey [J]. Mathematical Biosciences and Engineering, 2024, 21(1): 679-711.

作者简介:

孙延鹏 男,博士,教授,主要研究方向为航空电子系统、电磁兼容设计、雷达信号处理、嵌入式系统应用。

石增辉(通信作者) 男,硕士,主要研究方向为雷达信号处理技术。

屈乐乐 男,博士,教授,主要研究方向为超宽带雷达信号处理技术、稀疏微波成像技术、人体行为雷达识别技术。

DOI:10.3969/j.issn.1672-2337.2026.01.010

一种基于最邻近相似度模型的捷变雷达 辐射源识别方法

夏冬玉¹, 贾军帅¹, 张 玉¹, 董华智²

(1. 中国人民解放军93209部队, 北京 100085; 2. 北京无线电测量研究所, 北京 100854)

摘要: 针对捷变雷达信号载频、脉冲重复间隔、脉宽等多参数捷变导致传统参数匹配识别率低、鲁棒性差的问题, 提出一种基于最邻近相似度模型的捷变雷达辐射源识别方法。该方法通过测量提取多组载频、重复间隔、脉宽等测量准确的强特征参数与脉内时频特性特征相结合, 利用正态型隶属度函数构建基于最邻近相似度模型, 对多组捷变参数进行累加匹配计分, 以总得分最高为判定准则输出识别结果。仿真结果表明, 该方法在宽带捷变条件下的识别鲁棒性优于传统方法, 算法复杂度低、时效性强, 具有良好的工程应用前景。

关键词: 捷变雷达; 辐射源识别; 最邻近相似度模型; 计分制

中图分类号: TN971; TN958.6

文献标志码: A

文章编号: 1672-2337(2026)01-0094-05

引用格式: 夏冬玉, 贾军帅, 张玉, 等. 一种基于最邻近相似度模型的捷变雷达辐射源识别方法[J]. 雷达科学与技术, 2026, 24(1): 94-98.

XIA Dongyu, JIA Junshuai, ZHANG Yu, et al. An Agile Radar Emitter Identification Method Based on the Nearest Neighbor Similarity Model[J]. Radar Science and Technology, 2026, 24(1): 94-98.

An Agile Radar Emitter Identification Method Based on the Nearest Neighbor Similarity Model

XIA Dongyu¹, JIA Junshuai¹, ZHANG Yu¹, DONG Huazhi²

(1. Unit 93209 of PLA, Beijing 100085, China;

2. Beijing Institute of Radio Measurement, Beijing 100854, China)

Abstract: Aiming at the problem of low recognition accuracy and poor robustness of traditional single-group parameter matching caused by multi-parameter agility such as carrier frequency, pulse repetition interval and pulse width in agile radar emitters, an agile radar emitter identification method based on the nearest neighbor similarity model is proposed. By measuring and extracting the core characteristic parameters such as carrier frequency, repetition interval and pulse width, combined with the characteristics of time-frequency characteristics in the pulse, the method uses the Gaussian membership degree function to construct the nearest neighbor similarity model. The total matching score is obtained by accumulating the matching scores of multiple sets of agility parameters, and the identification result is output with the criterion of the highest total score. The simulating results indicate that the proposed method has better recognition robustness than the traditional method under the condition of broadband agility. The algorithm has low complexity and strong timeliness, and has good engineering application prospects.

Key words: agile radar; emitter identification; nearest neighbor similarity model; scoring system

0 引言

雷达辐射源识别是电磁博弈对抗中的重要环节, 也一直是国内外学者研究的热点^[1-5]。随着现代雷达技术的不断发展, 大量复杂体制雷达相继出现, 特别是捷变雷达, 其能够在多种工作模式间灵活跳变切换, 可以实现载频、脉冲重复间隔

(Pulse Repetition Interval, PRI)、脉宽等表征辐射源特征的参数的快速捷变, 使得传统基于单组参数模板的识别方法因无法捕捉雷达的捷变特性, 出现匹配失效、识别率大幅下降的问题^[6]。

目前, 针对捷变雷达辐射源的识别方法主要分为两类: 一类是融合脉内调制、脉冲包络等精细特征的识别方法^[7-10], 此类方法识别精度较高, 但

脉内调制特征的提取对测量设备精度要求高,在低信噪比及复杂电磁环境下提取可靠性差、实现复杂度高;另一类是基于多参数融合的传统匹配方法,如灰色关联度法^[11]、区间数法^[12]等,此类方法以雷达特征参数为依据,实现简单,但现有方法多采用参数区间建模或单组参数多维度融合,未充分利用捷变雷达多组参数的捷变离散分布特征,在宽带捷变场景下仍存在匹配模糊、误识别率高的问题。

针对上述问题,结合实际应用中对识别实时性、鲁棒性的需求,提出一种基于最邻近相似度模型的捷变雷达辐射源识别方法。该方法提取辐射源脉间强参数与脉内调制等精细特征相结合,通过多组有效测量参数,利用经工程验证的正态型隶属度函数构建基于最邻近相似度模型,对多组捷变参数采用精细化计分规则量化单组匹配度,以总得分排序作为识别准则,充分利用捷变雷达的参数离散分布特性,本文补充了模型核心参数的选择依据、特征权重与容差的设定方法、脉内时频特征的工程化计算流程,并通过多维度仿真验证了方法的有效性与工程实用性,为捷变雷达辐射源识别提供新的解决方案。

1 数据库构建规则

已知雷达辐射源数据库采用结构化存储,每条记录对应一个已知辐射源型号的一种工作模式,包含特征参数以及经统计标定的参数容差。参数容差用于适配辐射源信号的微小波动。

雷达参数数据库中第 j 类雷达的第 k 类工作模式的脉冲参数条目用集合表示为

$$D_{jk} = \{d_{jk1}, d_{jk2}, \dots, d_{jkm}, \sigma_{RF_{jk}}, \sigma_{PRI_{jk}}, \sigma_{PW_{jk}}\} = \{\{RF_{jk1}, PRI_{jk1}, PW_{jk1}, IM_{jk1}\}, \dots, \{RF_{jkm}, PRI_{jkm}, PW_{jkm}, IM_{jkm}\}, \sigma_{RF_{jk}}, \sigma_{PRI_{jk}}, \sigma_{PW_{jk}}\} \quad (1)$$

式中, $m = 1, 2, \dots, M$, RF_{jkm} 、 PRI_{jkm} 、 PW_{jkm} 、 IM_{jkm} 分别代表第 m 组参数的频率、重复间隔、脉宽值、脉冲调制类型相似度。 $\sigma_{RF_{jk}}$ 、 $\sigma_{PRI_{jk}}$ 和 $\sigma_{PW_{jk}}$ 分别代表频率、重复间隔和脉宽的容差。容差值由侦察接收机的参数测量误差统计(3σ 准则)标定,代表单次脉冲测量误差,适配工程实际场景。

2 基于最邻近相似度模型的识别方法设计

本方法的整体框架如图1所示,主要分为特征参数测量、辐射源数据库构建、正态型隶属度计算、特征参数匹配计分、累加匹配计分与识别判定等流程过程,全程以载频、重复间隔和脉宽的强特征为识别依据,鲁棒性高,受干扰或低信噪比影响小,且工程实现简单。




图1 整体框架图

2.1 基于深度学习模型脉内匹配计分

分析雷达信号脉内调制模式主要通过时频图,单载频、线性调频、二相编码、四相编码等信号在时频域有明显区别。卷积神经网络是一种前馈神经网络,卷积神经网络在图像方面能够给出更好的结果。

采用单载频、线性调频、二相编码、四相编码等信号的时频图作为卷积网络的输入数据集。为兼顾脉内特征提取的时效性与工程可实现性,本方法时频变换可采用短时傅里叶变换实现,结合统一尺度变换到 32×32 图像尺寸,计算量小,实时性高,利于工程应用。图2给出数据集中不同信号的时频图部分示例。




图2 时频图数据集




图3 卷积神经网络训练模型

对侦察得到的雷达信号进行 STFT 时频变换,生成 32×32 的时频图并输入训练好的轻量化 CNN 模型,模型输出调制信号识别概率,该流程计算在嵌入式设备上耗时在十几毫秒到几十毫秒级别,满足工程实时性要求。

2.2 基于最邻近相似度模型脉间匹配计分

系统接收捷变雷达辐射源的脉冲信号,测量出信号的载频、重复间隔和脉宽值,经过信号分选得到目标的脉间信号特征集合。

$$S = \{S_1, \dots, S_i\} = \{\{RF_i, PRI_i, PW_i\}, L, \{RF_i, PRI_i, PW_i\}\}, (i = 1, 2, \dots, N) \quad (2)$$

式中, RF_i 、 PRI_i 和 PW_i 分别代表频率、重复间隔和脉宽, N 是组数。

最邻近相似度模型匹配计分的核心是将脉冲信号测量特征集合 S 与数据库中某条目 D_{jk} 的多组捷变参数集合进行逐组双向最优匹配,采用先单组参数匹配度计算,再累加所有匹配组的得分得到该条目的总匹配分。该过程分为单参数匹配度计算、单组特征单元匹配度融合、最优匹配与得分累加 3 个步骤。

卷积神经网络训练模型构建如图 3 所示。模型结构经轻量化设计,兼顾识别精度与计算效率,其中输入层统一为 32×32 矩阵,3 通道时频图数据集。第一卷积层卷积核为 5×5 矩阵,第二卷积层卷积核为 3×3 矩阵,卷积步长均为 1,激活函数为 Re-Lu 函数。池化层采用最大池化法。最后通过 Softmax 输出判别为 4 类,分别对应线性调频、二相编码、四相编码信号的识别概率 $P(n)$ 作为计分项,其中 $n = 1, 2, 3, 0 < P_n < 1$ 。

1) 单参数匹配度计算

载频、重复间隔、脉宽等特征测量准确、精度高,每种参数组合自成一类,不适合复杂分类算法,而适合采用基于最近邻评估方法,建立基于模糊评判的正态型隶属度函数,利用欧式距离构建基于最邻近相似度模型。

定义 S_i 的参数与 d_{jkm} 相应参数之间的加权距离如下,加权距离考虑相应参数统计特性的影响,即容差 σ_i 大的参数在分类时其加权值 $1/\sigma_i$ 较小。

$$RF_{ijkm} = \frac{RF_i - RF_{ikm}}{\sigma_{RF_{jk}}} \quad (3)$$

$$PRI_{ijkm} = \frac{PRI_i - PRI_{ikm}}{\sigma_{PRI_{jk}}} \quad (4)$$

$$PW_{ijkm} = \frac{PW_i - PW_{ikm}}{\sigma_{PW_{jk}}} \quad (5)$$

测量参数隶属函数定义为

$$y(x) = 1 / \left(1 + \left(\frac{x}{a} \right)^n \right) \quad (6)$$

传统参数匹配方法中常用的正态分布隶属度函数为单参数高斯函数,而本文选用的正态型隶属度函数为双参数形式,相比单参数高斯函数,可通过两个参数灵活调节函数的陡峭程度与收敛速

度,更适配不同雷达的参数匹配需求,该函数形式连续可微,其表达式更贴合侦察参数匹配的实际分布特性。通过大量仿真与工程实测数据标定,当 $a=3, n=4$ 时,函数隶属度缓慢下降,贴合微小波动特性,该参数组合在典型雷达的工程测试中,匹配准确率优于其他参数组合。

根据式(6),则频率、脉宽、重复间隔的匹配度计算如下:

$$y(PRI_{ijkm}) = 1 / \left(1 + \left(\frac{PRI_{ijkm}}{3} \right)^4 \right) \quad (7)$$

$$y(PW_{ijkm}) = 1 / \left(1 + \left(\frac{PW_{ijkm}}{3} \right)^4 \right) \quad (8)$$

$$y(RF_{ijkm}) = 1 / \left(1 + \left(\frac{RF_{ijkm}}{3} \right)^4 \right) \quad (9)$$

2) 单组特征单元匹配度融合

由于同一特征单元内的载频、重复间隔、脉宽具有强绑定性,且不同参数在辐射源识别中的测量准确度不同,载频的准确度最高,重复间隔与脉宽次之,因此对单参数匹配度进行加权融合,得到单组特征单元的整体匹配度。

雷达辐射源测量值 i 组数据与数据库第 j 类雷达第 k 类工作模式的 m 组参数的匹配计分为

$$U_{ijkm} = \alpha \cdot y(PW_{ijkm}) + \beta \cdot y(PW_{ijkm}) + \gamma \cdot y(PRI_{ijkm}) + \delta \cdot P(IM_{ijkm}) \quad (10)$$

其中,融合求和的前三项为脉间特征匹配识别概率,最后一项为脉内匹配识别概率,取权重系数 $\alpha + \beta + \gamma + \delta = 1$,计分参数归一化。权重系数的取值与使用的侦察设备相关,通常测量精度高的参数权重系数取大些,测量精度低的参数权重系数取小些。单组特征单元的匹配度范围为0~1,值越接近1,表明该组测量参数与数据库条目参数的匹配程度越高,实现了单组强参数的精细化计分。

当 $U_{ijkm} > Th$ (匹配阈值)时, U_{ijkm} 即为单组匹配得分。否则判定为不匹配,得分为0。

3) 最优匹配与得分累加判定识别

为避免因测量参数组与数据库参数组的顺序不一致导致的匹配漏判,采用遍历匹配:

首先,初始数据库所有条目的分值为0。

其次,测量值的每组数据,与数据库条目中每

类雷达每类工作模式的每组数据进行单组匹配,匹配有效成功为该条目匹配度加分;遍历测量值所有组参数和数据库中所有组参数,累加所有有效匹配分,得到数据库条目每类雷达每类工作模式的总匹配分 P_{jk} 。遍历匹配确保测量值的每一组有效参数都能与数据库条目中进行匹配,充分利用了测量值离散特性与数据库的多组参数特征,总匹配分 P_{jk} 的范围为0~ m ,值越高,说明匹配组数越多、匹配度越高,得分越高。该方法同样适用信号不捷变情况,此时 $m=1$ 。

最后,对所有总得分 P_{jk} 进行降序排序。为避免因不同雷达的参数特征相似导致的误识别,引入得分领先阈值 θ ($\theta > 0$),若最高总匹配分 $P(1)$ 与次高总匹配分 $P(2)$ 的差值满足 $P(1) - P(2) \geq \theta$,则直接判定 $P(1)$ 为识别结果,即测量信号为 $P(1)$ 对应的雷达型号与工作模式;若 $P(1) - P(2) < \theta$,则判定为“疑似目标”,给出两组可能目标型号与工作模式。

3 仿真分析

3.1 捷变程度对识别准确率的影响

仿真模拟10类捷变雷达生成数据库,每类雷达包含10种工作模式,共100个雷达-模式组合作为识别目标。捷变幅度等级分为4类,即无捷变、小捷变(截变带宽 ± 100 MHz,重复间隔波动 ± 5 μ s,脉宽波动 ± 0.1 μ s)、中捷变(截变带宽 ± 300 MHz,重复间隔波动 ± 12 μ s,脉宽波动 ± 0.3 μ s)、大捷变(截变带宽 ± 400 MHz,重复间隔波动 ± 20 μ s,脉宽波动 ± 0.4 μ s),重叠程度随等级提升递增(无重叠 $\rightarrow$ 轻微重叠 $\rightarrow$ 中度重叠 $\rightarrow$ 高度重叠),脉内调制分为单载频、线性调频、二相编码、四相编码。匹配隶属度权重统一设置为载频0.4、PRI 0.3、脉宽0.2,调制类型0.1。

对以上不同捷变情况下模拟雷达信号进行100次识别仿真,结果如图4所示,从图中可以看出,本文方法对无捷变雷达辐射源识别准确率大于98%,随着雷达归一化捷变量增大目标识别准确率逐渐下降,在归一化捷变量为0.5时仍大于85%,明显优于灰色关联法的71%和区间数法的68%,具有良好的雷达辐射源识别效果。




图4 捷变量对识别准确率影响仿真结果

3.2 信噪比对识别准确率的影响

在大捷变等级下,改变输入信号的信噪比(0~20 dB),进行100次独立识别仿真,结果如图5所示。结果表明:所提方法在信噪比 ≥ 5 dB时,识别准确率稳定在80%以上;在信噪比 ≥ 10 dB时,识别准确率 $\geq 85\%$;而灰色关联法与区间数法在信噪比 ≤ 5 dB时,识别准确率均低于60%。原因在于所提方法以载频、PRI、脉宽等强特征多组参数匹配积分,比扩大模糊区间匹配等方法更加准确贴合信号的捷变频离散特征,同时兼顾了脉间强特征的鲁棒性与脉内精细特征的分度。




图5 大捷变下信噪比对识别准确率影响仿真结果

4 结束语

针对捷变雷达辐射源参数捷变导致传统识别

方法鲁棒性差、识别率低的问题,结合工程实际的识别需求,提出一种基于最邻近相似度模型的捷变雷达辐射源识别方法,以载频、重复间隔、脉宽等强测量参数为脉间特征识别依据,结合基于轻量化深度学习的脉内特征识别,简单有效却对实际信号适应性强,通过经工程标定的正态型隶属度函数构建最邻近相似度模型,对多组捷变参数进行累加匹配计分,以总得分最高为判定准则输出识别结果,充分利用了捷变雷达的多组参数分布特征,引入得分领先阈值,避免了因参数特征相似导致的误识别,有效提升识别效能。

所提方法算法复杂度低、受噪声影响小,工程实现简单。后续研究可引入多传感器数据融合技术,融合多个节点的测量参数,进一步提升对低信噪比、高捷变雷达信号的识别性能;同时可对隶属度函数进行自适应优化,根据不同雷达的捷变特性自动调整参数,提升方法的泛化能力。

参考文献:

- [1] 周志文,黄高明,陈海洋,等.雷达辐射源识别算法综述[J].电讯技术,2017,57(8):973-980.
- [2] NISHIGUCHI K, KOBAYASHI M. Improved Algorithm for Estimating Pulse Repetition Intervals [J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36 (2): 407-421.
- [3] NIRANJAN R K, RAO C R, SINGH A K. Real-Time Identification of Exotic Modulated Radar Signals for Electronic Intelligence Systems[C]//2021 Emerging Trends in Industry 4.0, Raigarh, India: IEEE, 2021: 1-4.
- [4] 王艺卉,闫文君,段可欣,等.基于数据增强的小样本辐射源个体识别方法[J].雷达科学与技术,2024,22(1): 104-110.
- [5] 徐涛,刘章孟,郭福成.基于高维重频特征的雷达辐射源识别方法[J].现代雷达,2024,46(4):1-7.
- [6] 薛坚.雷达辐射源信号识别关键技术研究[D].南京:南京大学,2021.
- [7] GAO Lipeng, ZHANG Xiaoli, GAO Jingpeng, et al. Fusion Image Based Radar Signal Feature Extraction and Modulation Recognition [J]. IEEE Access, 2019, 7: 13135-13148.
- [8] 陈琳,唐骏,余跃,等.一种基于扩张残差网络的雷达信号识别方法[J].电光与控制,2023,30(1):97-102.
- [9] SHI Qingang, ZHANG Jiafen. Radar (下转第109页)

基于航迹特征原型选择的军民船双分支融合识别

张鑫¹, 王海斌², 莫嘉倩¹, 史华莹², 刘钢²

(1. 中国人民解放军92728部队, 上海 200436;
2. 中国人民解放军91306部队, 上海 200436)

摘要: 雷达对海面军民目标的精确分类识别, 是海面态势信息生成的坚实基础, 对维护海上安全具有重要意义。当前研究多基于航迹特征识别军民船, 而现有方法或依赖单帧静态特征, 难以应对军船伪装行为; 或采用单一深度时序模型, 易受噪声干扰。为解决上述问题, 本文提出一种基于航迹特征原型选择的军民船双分支融合识别方法。本方法采用特征数据原型选择方法缓解类别不平衡问题, 并构建静态分支与时空分支, 分别处理瞬时特征与时序模式, 其中时空分支设计一种自适应膨胀卷积时序卷积网络, 能根据航迹局部平滑度动态调整感受野, 高效捕获战术机动模式; 最后采用自适应置信加权机制, 结合证据融合机制, 实现上下文感知的证据融合。所提方法在真实航迹数据集上军船识别准确率达到95.2%。

关键词: 航迹特征; 原型选择; 军民船识别; 时序卷积网络; 双分支融合

中图分类号: TN973

文献标志码: A

文章编号: 1672-2337(2026)01-0099-11

引用格式: 张鑫, 王海斌, 莫嘉倩, 等. 基于航迹特征原型选择的军民船双分支融合识别[J]. 雷达科学与技术, 2026, 24(1): 99-109.

ZHANG Xin, WANG Haibin, MO Jiaqian, et al. Dual-Branch Fusion Recognition of Military and Civilian Vessels Based on Trajectory Feature Prototype Selection [J]. Radar Science and Technology, 2026, 24(1): 99-109.

Dual-Branch Fusion Recognition of Military and Civilian Vessels Based on Trajectory Feature Prototype Selection

ZHANG Xin¹, WANG Haibin², MO Jiaqian¹, SHI Huaying², LIU Gang²

(1. Unit 92728 of PLA, Shanghai 200436, China;

2. Unit 91306 of PLA, Shanghai 200436, China)

Abstract: The accurate classification and recognition of maritime military and civilian targets by radar plays a foundational role in generating situational awareness of sea surfaces and holds significant importance for maritime security. At present, most of the research is based on trajectory features to identify military and civilian vessels, while the existing methods rely on single-frame static features, which is difficult to deal with the camouflage behavior of military vessels. Or employing single deep temporal models that are susceptible to noise interference. To address these challenges, this paper proposes a dual-branch fusion recognition framework for military and civilian vessels based on trajectory feature prototype selection. The method first employs a feature data prototype selection strategy to mitigate category imbalance problems. Then, two parallel branches are constructed: a static branch for instantaneous feature processing and a spatio-temporal branch for temporal pattern analysis. Notably, the spatio-temporal branch incorporates an adaptive dilated convolutional temporal convolutional network that dynamically adjusts its receptive field according to local trajectory smoothness, enabling efficient capture of tactical maneuver patterns. Finally, an adaptive confidence weighting mechanism combined with Dempster-Shafer evidence theory is implemented to achieve context-aware evidence fusion. Experimental results on the real trajectory dataset demonstrate that the proposed approach achieves the accuracy of 95.2% in the identification of military vessels.

Key words: trajectory features; prototype selection; military and civilian vessel recognition; temporal convolutional network; dual-branch fusion

0 引言

领海安全是国防安全的重要组成部分,是国家主权和领土完整的重要保障。当前我国周边政治军事局势复杂多变,领海安全受到严重威胁,因此需要加强对领海区域尤其是远海区域的海情监控,以便能够及时发现异常情况并做出应对措施。利用运动平台雷达进行海上预警监视,是获取海上态势信息的重要手段。在此过程中,需要对运动平台雷达发现的海面目标进行军民舰船分类识别,根据监视军舰或民船的航迹特征判断其类型与意图^[1-3]。然而,该任务面临严峻挑战:一方面,军用舰艇常通过低速巡航、直线航行等方式刻意模仿民船行为以实施伪装;另一方面,民用科考船、救援船等在执行特殊任务时也可能表现出类似军舰的高机动性轨迹,导致误判。

当前,国内外研究学者提出了多种海面目标分类识别方法,实现对军民目标的区分。武汉第二船舶设计研究所的沈梦家等人提出了一种基于航迹特征的舰船识别方法,通过深度残差网络模型进行深度特征提取,提升舰船识别的准确率^[4]。海军航空大学的夏栋等人则开展了基于航迹和船舶自动识别系统(AIS)信息等多维特征融合的海面军民目标精细分类,有效提高了海上目标的分类识别能力^[5]。中国电科第二十八研究所与中国航天科工集团8511研究所的相关研究人员则根据雷达航迹特征做出识别,继而利用Dempster-Shafer(DS)证据理论对各信息源上报的识别结果进行融合识别,以实现对面目标军民属性的判别^[6]。中国电科第三十八研究所的田西兰等人提出一种合理假设:合作目标的数据分布与非合作目标数据分布基本一致,在此基础上提出了一种基于数据驱动的海面目标分类器设计方法,通过两种目标的样本数据更新优化分类器^[7]。张晨等人利用集成学习和深度学习方法,集成随机森林模型、深度森林模型、卷积神经网络(CNN)模型和双向门控循环单元(BiGRU)模型,提出评估因子合成模型进行海上目标分类识别^[8]。基于区域轨迹聚类的目标分类方法侧重于通过空间区域内的航迹聚集特性,判断多数轨迹是否集中于同一地理范围。该

方法在实验中实现了84.4%的分类准确率,处理速度可达每秒9艘船舶^[9]。文献[10]则提出了一种基于支持向量机(SVM)的分类策略:首先采用分段线性拟合对航迹进行分割,以区分动态与静态运动状态;随后,将分割后轨迹之间的相似性度量构造为核函数,用于舰船运动模式识别。然而,该方法仅适用于局部海域场景,在依赖大规模训练样本的情况下,其准确率仅为76.3%,且处理效率较低,平均每秒仅能识别2个目标。此外,在航迹数据稀疏的区域,模型性能难以进一步提升。文献[11]则通过轨迹分割与多项式曲线拟合,从原始航迹中提取形状特征,并以此构建分类器,实现对舰船运动行为的判别。尽管上述研究在海面目标识别领域取得了一定进展,但仍存在局限性:基于多源信息融合的方法^[5-6]虽能提升精度,但高度依赖AIS等合作信号,在非合作或强对抗场景下实用性受限;而基于深度学习的端到端模型^[4,8]则对训练数据的质量和规模要求极高,且其“黑箱”特性导致决策过程缺乏可解释性;增量学习^[7]和集成学习^[8]策略虽能缓解数据分布偏移问题,但在面对精心设计的航迹伪装时,其鲁棒性仍有待验证。

综上,现有方法可归纳为两大技术路线:静态特征分析法与深度时序建模法。前者(如XG-Boost^[12]、SVM)计算高效、特征重要性清晰,但因其“快照式”的决策逻辑,无法利用历史轨迹上下文信息,在面对精心设计的伪装航迹时鲁棒性不足。后者(如LSTM、Transformer^[13])通过学习多帧序列的动态模式来提升识别能力,性能优越,但对单帧传感器噪声或短暂异常机动过于敏感,且模型复杂度高,不利于工程部署。基于上述两类方法,本文提出静态分支与时空分支证据融合框架,旨在协同利用瞬时物理约束与长期行为模式,实现既准确又可解释的最终决策。本文的主要贡献如下:

1) 提出自适应膨胀时序卷积网络(Adaptive-Dilation Temporal Convolution Network, AD-TCN):在标准TCN^[14]基础上,引入一个轻量级上下文编码器,根据航迹局部平滑度动态调整卷积膨胀率,使网络能在平稳段聚焦细节、在机动段捕捉广域战术模式。

2) 构建双分支证据融合架构:并行部署一个静态分支(基于原型选择的XGBoost)和一个时空分支(AD-TCN),将二者输出视为独立证据源,而非简单拼接或投票。

3) 设计自适应置信加权与证据融合机制:通过一个小型门控网络,依据当前轨迹上下文信息动态生成两个分支的可靠性权重,并利用DS证据理论合成结果,实现既准确又可解释的最终决策。

1 基于静态分支与时空分支融合的军民船识别方法

1.1 总体设计

如图1所示,本文所提基于航迹特征的海面军民目标识别流程包括数据预处理、特征选择、XGBoost模型的识别结果预测、AD-TCN模型的识别结果预测、以及基于自适应置信加权与DS证据理论的决策融合等环节。本文所指的“雷达航迹数据”是由运动平台雷达持续观测海面目标所形成的时间序列,其每一时刻的观测点包含目标的二维位置(经度、纬度)、运动状态(速度、航向)及其变化率(速度变化率、航向变化率)等六维特征,上

述特征具有明确的物理意义,可从空间位置、运动状态以及机动能力对军民船特性进行描述。

数据预处理是对原始雷达航迹数据进行清洗、归一化和标准化等操作,以提高数据质量并为后续模型输入提供高质量的特征数据。数据清洗主要是删除运动平台雷达数据中因处理异常产生的空值或无穷大值的航迹点,并对相邻距离过大的航迹点进行修正或删除。其中对异常值数据清洗工作可按照一定规则知识自动完成处理,而距离过大航迹点的数据清洗工作主要通过前期人工校验和设置对应规则过滤完成。经过上述数据清洗工作,目标航迹数据的准确性、可用性和一致性都将得到提升。随后,对清洗后的数据进行归一化处理,将航迹数据的各特征值归一化到 $[0, 1]$ 区间,消除不同特征量纲对模型训练的影响;同时进行标准化处理,使数据均值为0,方差为1,从而提高模型的收敛速度和稳定性。

通过计算任意两个特征之间的皮尔逊相关系数,确保所选特征之间的相关性较低,从而避免冗余信息。结果表明,这6个特征的相关性均低于0.5,大部分在0.1以下,适合作为独立特征输入模型。此外,利用XGBoost模型的特征分裂点使用频率对这6个特征的重要性进行了评估,结果显示经度、纬度、速度变化率和航向变化率对分类任务的贡献较大,但最终仍然保留了所有6个特征作为模型输入,以充分利用航迹数据的多维信息。

经过数据预处理与特征选择后,使用训练数据集分别对XGboost模型和AD-TCN模型进行训练与参数优化,优化完后保持两个分支的模型参数固定,对自适应置信加权模块进行优化,最后使用测试数据集对训练好的模型进行测试以得到识别结果,进行DS证据融合得到融合决策结果。




图1 基于航迹特征的海面军民目标识别流程图

1.2 基于原型选择的XGBoost静态分支军民船识别

本节所述的原型选择旨在缓解军民船样本数量不均衡问题,而非进行特征维度的选择。在海上目标的雷达探测场景中,由于民用目标船只(如商船、渔船)数量远多于军事目标(如军用船只、侦察船),导致目标的航迹数量存在明显的不平衡性

问题。不平衡数据会导致分类器更倾向于预测高频出现目标(民目标),从而降低对低频出现目标(军目标)的识别能力。针对上述问题,提出了一种基于反向K近邻的原型选择方法,缓解不同类别数据规模不平衡对分类性能的影响,并结合XGBoost模型构建分类模型。XGBoost通过集成多个弱学习器来构建预测模型。其目标函数中引入了表征树模型复杂度的正则化项,使得对目标函数的近似优化更贴近实际值,从而有效提升了预测精度。

基于反向K近邻的原型选择方法通过计算每个样本被其他样本视为K近邻的次数得到其反向K近邻计数,反向K近邻计数大的样本通常更具有代表性,选择反向K近邻计数大的样本作为原型。反向K近邻计数的公式表示为

$$R_i = \sum_{j=1}^N I(x_i \in KNN(x_j)) \quad (1)$$


式中, R_i 表示样本 x_i 的反向K近邻计数, $KNN(x_j)$ 表示样本 x_j 的K近邻集合, $I(\cdot)$ 表示指示函数。

对原型选择前后的军民目标数据进行t分布随机邻域嵌入(t-distributed Stochastic Neighbor Embedding, t-SNE)降维后的数据分布如图2所示,展示高维数据在二维空间中的分布。


选择反向K近邻计数值较大的样本作为原型后,将其作为中心,剔除其K近邻范围内的其他样本,避免数据冗余。通过以上原型选择,军民目标航迹数据的数量更加均衡,且原型样本保留了类别的关键特征,适合用于后续XGBoost模型训练。

在完成原型选择后,基于目标航迹的特征构建输入数据集,并使用XGBoost模型进行军民目标分类。给定任意一个样本,XGBoost模型通过累加该样本在每个分类回归树上的预测结果,并实现输出概率分布 $P_s = [p_s^J, p_s^M]$,其中s为XGBoost模型输出概率标志,J表示军船类别,M表示民船类别。

对于具有n个样本和m个特征的给定带有标记类别的数据集 $D = \{(x_i, y_i) | |D| = n, x_i \in \mathbb{R}^m, y_i \in \mathbb{R}\}$,其中 (x_i, y_i) 表示特征向量与对应的类别,XGBoost模型使用K个加法函数来预测输出,具体



(a) 原始数据分布图



(b) 原型选择后数据分布图

图2 军民目标原型选择前后数据分布对比图

公式为

$$\hat{y}_i = \phi(x_i) = \sum_{k=1}^K f_k(x_i), \quad f_k \in F \quad (2)$$

式中, x_i 表示第i个数据点的特征向量, $f_k(x_i)$ 表示回归树,分类回归树集合空间F的表达式为

$$F = \{f(x) = \omega_{q(x)}\} (q: \mathbb{R}^m \rightarrow T, \omega \in T) \quad (3)$$

式中,T表示该树的叶子节点数量, ω 表示叶子节点分数, $\omega_{q(x)}$ 表示分类回归树对样本的预测值。

XGBoost的目标函数包括两部分,可表示为

$$L(\phi) = L(\theta) + \Omega(\theta) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (4)$$

式中, $l(\hat{y}_i, y_i)$ 是可微凸损失函数,定义为测量预测 $\hat{y}_i$ 与目标 y_i 之间的差异, $\Omega(\theta)$ 是采用正则化项降低模型的过拟合风险。通常,可由内部树的深

度、节点的个数、叶子节点的个数 T 和叶子节点的分数 ω 等来衡量模型的复杂度。目标函数中用来调整树复杂度的正则项为

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2 \quad (5)$$

式中, γ 与 λ 是控制参数。在模型迭代过程中, 前次迭代的损失函数变量是拟合残差的损失与新树的复杂度惩罚之和, 具体表达式为

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i)) + \Omega(f_t) \quad (6)$$

式中, $f_t(\mathbf{x}_i)$ 为第 t 轮新增的弱学习器的输出结果, $\hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i)$ 为新一轮的输出。为了快速优化目标, 采用二阶泰勒展开近似, 得到如下目标函数:

$$L^{(t)} \approx \sum_{i=1}^n \left[l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t^2(\mathbf{x}_i) \right] + \Omega(f_t) \quad (7)$$

式中, g_i 和 h_i 分别是第 i 个采样点的损失函数的第二个变量的一阶和二阶偏导数:

$$g_i = \partial_{\hat{y}^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)}) \quad (8)$$

$$h_i = \partial_{\hat{y}^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)}) \quad (9)$$

将常数项替换可以得到

$$\tilde{L}^{(t)} = \sum_{i=1}^n \left[g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t^2(\mathbf{x}_i) \right] + \Omega(f_t) \quad (10)$$

进一步由式(2)和(4)可得

$$\tilde{L}^{(t)} = \sum_{i=1}^n \left[\left(\sum_{j \in I_j} g_i \right) \omega_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) \omega_j^2 \right] + \gamma T \quad (11)$$

式中, $I_j = \{i | q(\mathbf{x}_i) = j\}$ 作为叶子 j 的实例集, 按照叶节点累加的形式, 可以将目标函数写成:

确定了树的结构之后, 设置目标函数的导数为0, 得到每个叶节点的最优预测分数为

$$\omega_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (12)$$

带入目标函数, 得到最小损失为

$$\tilde{L}^{(t)}(q) = - \frac{1}{2} \sum_{j=1}^T \frac{\left(\sum_{i \in I_j} g_i \right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (13)$$

军民目标航迹特征通常有一定差异。在运动特征上军用目标往往具有较高的速度和稳定的航向, 而民用目标则更趋于随机性; 在时空特征上,

某些特定军事禁区或航道以及特定的时间段可能更容易出现军事目标。XGBoost模型能够对多种类型的特征建模, 并自动捕获特征之间的非线性关系, 适用于航迹数据中多维异构特征的建模需求。

XGBoost可以通过特征分裂点的使用频率评估每个特征的重要性, 显示哪些航迹特征对军民目标分类具有更强的区分能力。图3展示了XGBoost模型对目标航迹各个特征重要性评估分数, 可知经度、纬度、速度变化率和航向变化率相较于速度、航向特征对军民目标分类具有更强的区分能力。




图3 特征重要性评估图

1.3 基于AD-TCN网络的时空分支军民船识别

给定一个长度为 T 的连续船舶轨迹观测序列 $\mathbf{X} = [\mathbf{x}_{t-T+1}, \dots, \mathbf{x}_t]$, 其中每一帧 $\mathbf{x}_i \in \mathbb{R}^6$ 包含[经度, 纬度, 速度, 航向, 速度变化率, 航向变化率], 目标是预测其类别标签 $\mathbf{y} \in \{\mathbf{J}, \mathbf{M}\}$ 。

时空分支处理 T 帧航迹序列 $\mathbf{X} \in \mathbb{R}^{T \times 6}$ 。AD-TCN网络主干由多个残差块构成, 每个块内包含空洞卷积层、激活层、正则化层与失活层。

在处理时序序列时, 由于数据前后之间存在依赖关系, 传统CNN已难以有效建模。本文所采用的航迹特征数据属于典型的时间序列传感器数据, 为捕捉其时序依赖性, 引入了空洞卷积这一改进的卷积形式, 以增强对时序信息的建模能力。空洞卷积通过在卷积核中引入扩张率, 在不增加参数量的情况下扩大感受野, 从而有效利用历史

时刻信息对当前或未来时刻的输出进行预测。在本文构建的AD-TCN网络中,通过特定的堆叠结构实现时序建模,如图4所示。该结构使得各层感受野随深度增加而扩展,从输入层至输出层依次增大,提升了网络对长程依赖的建模效率。




图4 AD-TCN网络

感受野的计算方式计算公式如下:

$$F = (rate - 1)(k - 1) + k \quad (14)$$

式中, F 、 $rate$ 和 k 分别表示感受野大小、扩张率和卷积核尺寸。当 $rate=1$ 时,空洞卷积退化为普通卷积,感受野保持一致,图4中第二层即采用此设置,卷积核大小为2时,其感受野大小为2。

自适应膨胀机制:由于军船的多帧航迹相对灵活,为使网络能在平稳段聚焦细节、在机动段捕捉广域战术模式,本文设计了自适应膨胀机制的TCN网络。对于AD-TCN网络的第 l 个残差块,其膨胀率 d_l 并非固定。本文引入一个轻量级上下文编码器(一个单层GRU),它分析输入序列的一个短窗口以计算局部平滑度指标 σ 。膨胀率据此动态调整: $d_l = \text{clip}(d_{\text{base}}(1 + \alpha(1 - \sigma)), d_{\min}, d_{\max})$ 。当 σ 较低(即航迹处于高机动状态)时, d_l 增大,使网络拥有更大的感受野以捕获战术背景;反之,在平稳段则使用较小的 d_l 以关注局部细节。最终输

出概率分布 $P_t = [p_t^J, p_t^M]$, 下标 t 为XGBoost模型输出概率标志。

1.4 自适应置信加权与DS证据融合机制

自适应置信加权模块是一个小型神经网络(两层MLP),其输入是 T 帧航迹序列 $X \in \mathbb{R}^{T \times 6}$, 输出两个可靠性分数 r_s 和 r_t , 分别代表静态与时序证据的可信度。这两个分数用于对两个模型输出的概率分布进行加权操作。

$$p^J = r_s p_s^J + r_t p_t^J \quad (15)$$

$$p^M = r_s p_s^M + r_t p_t^M \quad (16)$$

针对XGBoost和AD-TCN两种模型的识别结果,首先用自适应置信加权模块分配权重得到新的输出概率分布,再利用DS证据理论进行单帧融合和多帧融合,以获得更为准确的识别结果进行上报。

DS证据理论本质上是一种处理不确定性推理的方法,其基本前提是各证据之间相互独立且互不冲突。在应用过程中,通常需要排除具有较大冲突的证据,以保留多个证据中共同支撑的有效信息,进而提升融合结果的准确性与合理性。

为降低证据之间的冲突,本文采用了一种基于余弦相似度改进的DS证据理论融合方法。该方法通过计算各证据之间的余弦相似度,能够有效衡量不同证据源之间的相似程度,为后续的融合处理提供依据。该方法对于相似度较高的证据赋予更大的权重,而对相似度较低的证据则降低其权重,采用这种策略有助于削弱由异常数据引起的不利影响,从而降低证据冲突对融合结果的干扰。综上所述,本文方法通过对证据源进行修正,在一定程度上缓解了证据冲突问题,有效提升了信息融合过程的可靠性与结果的准确度。在本文的海面军民目标分类识别任务中,识别框架 Θ 被定义为: $\Theta = \{J, M\}$ 。DS理论将基本概率分配(BPA)赋予 Θ 的任意子集 $Y \in 2^\Theta = \{\emptyset, \{J\}, \{M\}, \{J, M\}\}$ 。在这里,子集 $\{J, M\}$ 表示模型无法明确区分目标类型时的“不确定性”或“未知”状态。单帧或多帧情况下分支模型的输出(经过1.4节开头所述的自适应置信加权后)被直接视为对 Θ 的基本概率分配(Basic Probability Assignment, BPA)。

算法详细步骤如下所示:

1) 求各证据之间的余弦相似度。在DS证据理论中,基本概率分配定义在命题的任意子集上,用于分配概率质量,描述证据对某一命题的支持程度。假设一组证据体的BPA分别为: $m_1, m_2, \dots, m_n$,通过计算两组证据之间的余弦相似度 $\text{Sim}(m_i, m_j)$,可衡量其关联程度。该相似度的取值范围为 $[0, 1]$ 。

$$\text{Sim}(m_i, m_j) = \frac{m_i \cdot m_j}{\|m_i\| \cdot \|m_j\|} \quad (17)$$

当相似度趋近于0时,表明两个证据体高度不一致,呈正交关系;当相似度趋近于1时,说明二者高度一致;相似度值越大,表示证据间的相似性越强;反之则越弱。

2) 证据间相互支持度的计算。在获得相似度矩阵 Sim 后,可通过对每一证据与其他所有相关证据的相似度求和,得到其整体支持度 $\text{Sup}(m_i)$ 。具体计算公式如下:

$$\text{Sup}(m_i) = \sum_{j=1, j \neq i}^n \text{Sim}(m_i, m_j) \quad (18)$$

3) 计算每个证据体的可信度。证据的可信度用于衡量其对最终融合结果的影响程度,该值通过对各证据的支持度进行归一化处理获得。可信度 $\text{Cred}(m_i)$ 计算方式为

$$\text{Cred}(m_i) = \frac{\text{Sup}(m_i)}{\sum_{i=1}^n \text{Sup}(m_i)} \quad (19)$$

4) 使用权重系数修正原始证据体。利用可信度权重 $\text{Cred}(m_i)$ 对原始BPA $m_i(Y)$ 进行加权修正,得到新的BPA $m_i^{\#}(Y)$,表达式如下:

$$m_i^{\#}(Y) = \text{Cred}(m_i) m_i^*(Y) \quad (20)$$

这一步不仅按照相似度重新分配各个证据体的权重系数后,还通过后续的归一化处理,有效缓解了当某一证据对某类别(如 $\{J\}$)的BPA为0,而其他证据不为0时可能出现的“0信任悖论”问题。

5) 修正后的BPA进行归一化处理。

$$m_i^{\&}(Y) = \frac{m_i^{\#}(Y)}{\sum_{Y \in \Theta} m_i^{\#}(Y)} \quad (21)$$

6) 使用Dempster组合规则融合BPA。根据Dempster合成规则对其进行融合,合成结果如下: $\oplus$ 表示Dempster合成算子,将多个证据的BPA相乘,并根据它们之间的冲突程度进行归一化,用于组合多个BPA。

$$m(Y) = m_1^{\&}(Y) \oplus m_2^{\&}(Y) \oplus \dots \oplus m_n^{\&}(Y) \quad (22)$$

2 试验过程与结果分析

2.1 数据集介绍

本文选取某运动平台雷达在某海域的航迹监测数据,其中军船目标122批,军船航迹3211条,民船目标233批,民船航迹12933条。选取的航迹特征为经度、纬度、速度、航向、速度变化率和航向变化率6个属性。为确保6个属性参数之间相互独立,计算任意两个属性之间的皮尔逊相关系数。对于经度 X_1 、纬度 X_2 、速度 X_3 、速度变化率 X_4 、航向 X_5 和航向变化率 X_6 这6个航迹属性,有 n 个观测值(航迹点)。计算任意两个属性 X_i 和 X_j 之间的皮尔逊相关系数 r_{ij} 。

单对属性之间的皮尔逊相关系数计算公式为

$$r_{ij} = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kj} - \bar{x}_j)^2}} \quad (23)$$

式中 $i, j=1, 2, \dots, 6, x_{ki}$ 为第 k 个航迹点的第 i 个属性值, $\bar{x}_i$ 为第 i 个属性的均值, n 为航迹点总数。

6个航迹属性之间的皮尔逊相关系数矩阵:

$$R = \begin{bmatrix} r_{11} & r_{12} & r_{13} & r_{14} & r_{15} & r_{16} \\ r_{21} & r_{22} & r_{23} & r_{24} & r_{25} & r_{26} \\ r_{31} & r_{32} & r_{33} & r_{34} & r_{35} & r_{36} \\ r_{41} & r_{42} & r_{43} & r_{44} & r_{45} & r_{46} \\ r_{51} & r_{52} & r_{53} & r_{54} & r_{55} & r_{56} \\ r_{61} & r_{62} & r_{63} & r_{64} & r_{65} & r_{66} \end{bmatrix} \quad (24)$$

式中,对角线元素 $r_{ij} = 1$ (每个属性与自身完全相关),对称性 $r_{ij} = r_{ji}$,值域 $-1 \leq r_{ij} \leq 1$ 。

皮尔逊相关系数的计算步骤如下:

1) 计算每个属性的均值

$$\bar{x}_i = \frac{1}{n} \sum_{k=1}^n x_{ki} \quad (25)$$

2) 计算每个属性的离差平方和

$$SS_i = \sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \quad (26)$$

3) 计算每对属性的离差乘积和

$$SP_{ij} = \sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j) \quad (27)$$

4) 计算相关系数

$$r_{ij} = \frac{SP_{ij}}{\sqrt{SS_i \cdot SS_j}} \quad (28)$$

在本文选取的监测数据上计算任意两个属性之间的相关系数,结果如图5所示。




图5 海面军民目标6个属性的相关系数热力图

从图5可见,相关系数的值都不超过0.5,且大部分在0.1以下(1代表完全相关,0代表完全不相关),说明这6个参数相关性不高,可以作为海面军民目标识别的特征属性。

2.2 实验设置

1) XGBoost 模型训练

本文XGBoost模型训练中涉及的主要参数有5个,分别是学习率、树的最大深度、迭代次数、采样率和列采样。设置模型初始参数如表1所示。

表1 XGBoost海面目标识别模型参数初始值

参数类型	初始值
学习率	0.5
树的最大深度	2
迭代次数	150
采样率	0.1
列采样	1

2) AD-TCN 模型训练

针对海面舰船目标航迹特征的时序相关性,结合航迹上下文信息利用AD-TCN网络模型对航

迹特征进行深度挖掘,模型训练的参数初始值如表2所示。

表2 AD-TCN模型参数初始值

参数类型	初始值
学习率	0.05
迭代次数	150
基础膨胀率	1.0

2.3 实验结果

1) 基于XGBoost模型的实验结果

随机选择80%数据作为训练集,剩余数据则用于测试。采用五折交叉法进行验证,测试正确率取均值。首先使用未经过原型选择的原始训练集进行训练。经过训练后,利用测试数据对模型进行测试,得到相应的海面军民目标识别混淆矩阵,如图6所示。




图6 海面军民目标识别混淆矩阵

从图6可见,该模型识别民船能力更强,准确率可以达到91%,而识别军船能力相对弱些,准确率为82%。

上述识别目标的准确率是在XGBoost算法初始参数下计算获得的。通过调整模型参数可以提升性能,获得更高的识别准确率。因模型参数组合复杂度较高,故采用Optuna工具寻优方法对参数进行优化。

Optuna工具寻优方法是在原有的模型算法上结合专用的工具,以达到自动寻找最优参数组合的目的^[10]。Optuna工具能够动态构建超参数的搜索空间,基于网格搜索、随机搜索和贝叶斯搜索等不同算法的采样器,自动获取最优超参数值。根据先验知识,在Optuna方法下选择5个参数的搜索

空间如表 3 所示。

表 3 Optuna 方法下海面目标识别模型参数搜索空间

参数类型	取值范围	步长
学习率	[0.1, 1]	连续空间
树的最大深度	[1, 5]	1
迭代次数	[50, 750)	1
采样率	[0.1, 1]	连续空间
列采样	[0.1, 1]	连续空间

Optuna 工具寻优后的识别混淆矩阵如图 7 所示。




图 7 使用 Optuna 方法优化后的海面目标识别混淆矩阵

从图 7 可知,尽管民船识别能力略有下降,但是军船识别能力显著提升,其准确率达到 91%。

之后利用反向 K 近邻原型选择方法对训练集(军船航迹 2 569 条,民船航迹 10 346 条)进行原型选择,得到原型训练集,其中军船目标样本数量缩减到原来的 87%(2 235 条),民船目标样本数量缩减到原来的 45%(4 656 条)。重新训练与测试,军船识别准确率达到 92%,民船识别准确率达到 91%,如图 8 所示,军民目标的识别准确率均有所提升。




图 8 使用原型选择后的海面目标识别混淆矩阵

2) 基于 AD-TCN 模型的实验结果

随机选择 80% 数据为训练集,剩余数据则用于测试。采用五折交叉法进行验证,测试正确率取均值。在模型训练后,利用测试数据进行军民目标分类识别,试验结果如表 4 所示,可以看出 AD-TCN 模型对军船识别准确率达到 92%,对民船识别准确率达到 90%。

表 4 基于 AD-TCN 模型识别结果

军船识别准确率	民船识别准确率
92.79%	91.73%

3) 决策融合识别结果

针对 XGBoost 和 AD-TCN 两种模型的识别结果,利用改进的 DS 证据理论进行单帧融合和多帧融合,以获得更为准确的识别结果。如表 5 和表 6 所示,融合后对军船识别准确率提升到 95%,对民船识别准确率达到 92%,有效实现了对海面军民目标的分类识别。

表 5 单帧军民分类识别结果

方法	军船识别准确率	民船识别准确率
XGboost	92%	91%
LSTM	92.3%	91.45%
TCN	92.39%	91.2%
AD-TCN	92.79%	91.73%
单帧融合	94.8%	92.2%

表 6 多帧军民分类识别结果

军船识别准确率	民船识别准确率
95.04%	92.27%

融合模型提升体现在对军船的识别准确率提升显著(3%~4%),说明融合能更好识别伪装或异常行为。对民船提升较小(2%~3%),但整体稳定。

本文分析了单网络识别错误同时融合方法识别正确的航迹,有典型 3 种情况:①军船伪装航迹;②民船特殊任务;③传感器干扰。

图 9 典例 1 中 XGBoost 将低速巡航误判为民船(当前帧特征匹配度较高),而在融合模型中 DS 合成提高 AD-TCN 时序模式权重,强调时序一致性,修正了识别结果。

图 10 典例 2 中 AD-TCN 将货船误判为军船(异常加速度触发),而 XGBoost 利用静态结构特征结构特征修正冲突,融合识别判为民船。




图9 典例1航迹(早期机动、后期伪装)




图10 典例2航迹(Z字形轨迹)




图11 典例3航迹(轨迹存在噪声干扰)

图11典例3中由于出现了噪声航迹,双模型置信度均小于0.6,出现模糊轨迹,DS融合利用多帧上下文融合判决,综合置信度提升至0.81。

由上可以看出单模型在静态特征不足或时序异常敏感时易出错。DS融合模型利用互补优势实现纠错:XGBoost 补充结构特征,AD-TCN 补充时序模式。

2.4 效率分析

为评估模型的计算效率,在相同硬件平台(NVIDIA RTX 3090)上测试了各模型的推理速度,结果如表7所示。可以看出,本文所提XGBoost静态分支具有极高的推理效率,优于1 000 fps,而AD-

TCN时空分支因需处理时序信息,速度相对较低。最终的融合模型推理速度为75 fps,满足实时性要求。同时,融合模型的总参数量为 9.6×10^6 ,低于纯深度学习模型(如LSTM: 12.3×10^6),体现了良好的效率与精度平衡。

表7 各模型计算效率对比

方法	推理速度 / fps	参数量 ($\times 10^6$)
XGboost	1 217	0.5
LSTM	85	12.3
TCN	92	8.7
AD-TCN	78	9.1
单帧融合	75	9.6

综上所述,实验结果验证了所提单帧融合框架在复杂、低信噪比雷达环境下的工程实用性,为军民船等海面目标的可靠识别提供了有力支撑。

3 结束语

针对运动平台雷达对海面军民目标分类识别中因目标数据库不全面或其故意采取欺骗措施导致探测目标分类信息识别效果不佳的问题,本文提出了一种基于航迹特征的海面军民目标分类识别方法,利用AD-TCN和XGboost模型分别对运动平台雷达探测到的海上目标航迹进行特征提取与分类识别,并将识别结果进行决策融合,实现了海面军民目标的分类识别。试验结果表明,本文所提方法能大幅度地提升海面军民目标的识别准确率、稳定性和可靠性。由于识别过程未利用人工的先验知识与假设条件,因此,该方法具有良好的通用性。

参考文献:

- [1] 陈灿彬.运动平台雷达对海目标联合识别技术研究[J].舰船电子工程,2021,41(8):74-77.
- [2] 王曙光,田西兰.一种窄带雷达舰船目标分类的决策方法[J].雷达科学与技术,2016,14(2):159-162.
- [3] 张鹏飞,魏存伟,刘先康,等.窄带舰船目标识别方法研究[J].电子科技,2021,34(6):50-55.
- [4] 沈梦家,张军,金朝,等.基于多模态数据特征融合的舰船识别算法研究[J].光学与光电技术,2023,21(6):22-27.
- [5] 夏栋,张凯旋,马玲.机载雷达对海目标联合识别技术研究[J].舰船电子工程,2021,41(8):74-77.

- [6] 宁勇,朱伟强.海面目标多信源融合识别技术研究[J]. 航天电子对抗,2011,27(1):37-40.
- [7] 田西兰,李川,王曙光,等.基于数据驱动的窄带雷达舰船目标分类决策方法[J].空军预警学院学报,2021,35(3):181-183.
- [8] 张晨,靳俊峰.基于集成学习和深度学习的海上目标联合分类识别方法[J].空军预警研究学报,2024,38(6):411-415.
- [9] LEE J G, HAN Jiawei, LI Xiaolei, et al. TraClass: Trajectory Classification Using Hierarchical Region-Based and Trajectory-Based Clustering[J]. Proceedings of the VLDB Endowment, 2008,1(1):1081-1094.
- [10] DE VRIES G K D, VAN SOMEREN M. Machine Learning for Vessel Trajectories Using Compression, Alignments and Domain Knowledge[J]. Expert Systems with Applications, 2012,39(18):13426-13439.
- [11] ELWAKDY M, EL-BENDARY M, ELTOKHY M. A Novel Spatial Algorithm for Similar and Non-Similar Trajectories Classification of Different Objects[C]//International Conference on Frontiers in Education: Computer Science and Computer Engineering, Las Vegas, Nevada, USA:[s.n.],2015:168-177.
- [12] CHEN Tianqi, GUESTRIN C. XGBoost: A Scalable Tree Boosting System[C]// 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, CA, USA:ACM,2016:785-794.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[PP/OL].arXiv (2023-08-02) [2025-12-02]. <https://doi.org/10.48550/arXiv.1706.03762>.
- [14] BAI Shaojie, KOLTER J Z, KOLTUN V. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling[PP/OL].arXiv (2018-04-19) [2025-12-06]. <https://doi.org/10.48550/arXiv.1803.01271>.

作者简介:

张鑫(通信作者) 男,博士,工程师,主要研究方向为信息与通信工程。

王海斌 男,硕士,高级工程师,主要研究方向为预警探测数据分析。

莫嘉倩 女,硕士,工程师,主要研究方向为航空电子技术。

史华莹 女,本科,工程师,主要研究方向为雷达预警探测技术。

刘钢 男,硕士,助理工程师,主要研究方向为航空电子技术。

(上接第98页)

Emitter Signal Identification Based on Intra-pulse Features [C]//2022 IEEE 6th Information Technology and Mechatronics Engineering Conference, Chongqing, China: IEEE, 2022: 256-260.

- [10] 张立民,谭凯文,闫文君,等.基于多级跳线残差网络的雷达辐射源识别[J].系统工程与电子技术,2022,44(7):2148-2156.
- [11] 赵汝鹏,田润澜,张旭洲,等.基于相似度的雷达目标识别灰关联分析算法[J].电信科学,2017,33(5):82-89.
- [12] 李双明,关欣,赵静,等.一种参数区间交叉类型的目

标识别方法[J].北京航空航天大学学报,2020,46(7):1307-1316.

作者简介:

夏冬玉(通信作者) 男,博士,高级工程师,主要研究方向为无源探测技术。

贾军帅 男,硕士,高级工程师,主要研究方向为计算机信息处理。

张玉 女,硕士,高级工程师,主要研究方向为无源探测技术。

基于互补波形设计的频谱弥散干扰抑制方法

杨 贤^{1,2}

(1. 中国电子科技集团公司第五十四研究所, 河北石家庄 050081;

2. 河北省电磁频谱认知与管控重点实验室, 河北石家庄 050081)

摘要: 频谱弥散干扰是一种用于对抗脉冲多普勒雷达系统的典型有源转发式干扰。由于频谱弥散干扰分量与发射波形具有强相关性, 干扰回波经雷达系统脉冲压缩处理后会生成大量的梳状假目标, 达到对真实目标的遮蔽及压制效果。针对频谱弥散干扰抑制难题, 本文通过协同配置雷达系统的多发射脉冲参数, 提出一种基于多波形互补设计的主动式干扰对抗方法。在具体实现过程中, 首先建立了多波形体制下的频谱弥散干扰参数化模型, 然后在干扰响应最小化准则与波形互补旁瓣最小化准则下给出了兼顾干扰对抗与目标探测的波形设计模型; 为了进一步求解波形参数, 推导了波形参数的梯度表达式, 给出了基于共轭梯度算法的波形求解方法; 最后, 基于数值仿真数据与电磁计算数据的实验结果表明了所提方法的有效性。

关键词: 互补波形设计; 频谱弥散干扰; 干扰抑制; 共轭梯度法

中图分类号: TN974

文献标志码: A

文章编号: 1672-2337(2026)01-0110-9

引用格式: 杨贤. 基于互补波形设计的频谱弥散干扰抑制方法[J]. 雷达科学与技术, 2026, 24(1): 110-118.

YANG Xian. Smeared Spectrum Jamming Suppression Method Based on Complementary Waveform Design[J]. Radar Science and Technology, 2026, 24(1): 110-118.

Smeared Spectrum Jamming Suppression Method Based on Complementary Waveform Design

YANG Xian^{1,2}

(1. The 54th Research Institute of China Electronics Technology Group Corporation, Shijiazhuang 050081, China;

2. Hebei Key Laboratory of Electromagnetic Spectrum Cognition and Control, Shijiazhuang 050081, China)

Abstract: Smeared spectrum jamming is a typical active repeater jamming technique used to counter the pulse-Doppler radar system. Due to the strong coherence between the smeared spectrum jamming component and the transmit waveform, the jamming signals generate numerous comb-like false targets after the pulse compression processing by the radar system, so as to achieve the effects of masking and suppressing the real targets. Aiming at the problem of smeared spectrum jamming suppression, this paper proposes an active jamming countermeasure method based on multi-waveform complementary design by collaboratively configuring the multi-transmitting pulse parameters of the radar system. In the implementation process, firstly, a parametric model of smeared spectrum jamming under a multi-waveform system is established. Then, under the criteria of minimizing the jamming response and the waveform complementary pulse compression sidelobe, a waveform design model considering both jamming suppression and target detection is presented. To further acquire the waveform parameters, the gradient expression of the waveform parameters is derived, followed by a waveform optimization method based on the conjugate gradient algorithm. Finally, the experimental results based on numerical simulations and electromagnetic computation data demonstrate the effectiveness of the proposed method.

Key words: complementary waveform design; smeared spectrum jamming; jamming suppression; conjugate gradient method

0 引言

随着数字射频存储(Digital Radio Frequency Memory, DRFM)技术^[1-3]的不断发展,各类基于截获-调制-转发工作模式的有源相参式干扰相继涌现^[4-6]。其中,频谱弥散干扰是一种用于对抗经典线性调频(Linear Frequency Modulation, LFM)信号的典型有源转发式干扰。在实际工作中,由于与雷达发射波形具有强相参性,频谱弥散干扰在雷达接收机中经匹配滤波处理后会产生大量的梳状假目标,进而遮蔽真实目标,达到压制和欺骗效果。

针对频谱弥散干扰对抗难题,现有研究主要集中在接收端回波处理技术上。相关方法主要包括变换域滤波方法^[7-8]、信号重构方法^[9-11]以及多通道分离方法^[12-13]。其中,变换域滤波方法的工作原理在于将回波信号转换到不同的变换域,从而通过变换域滤波处理来分离目标信号。信号重建技术通过估计干扰参数来估计和对消干扰分量,从而获得纯净的目标信号。与前两种方法不同,多通道分离技术主要适用于目标和干扰之间存在空域或极化域差异的应用场景,主要思路是通过提取不同通道内的目标及干扰特征实现干扰抑制。然而在实际应用中,由于目标与干扰呈现严重耦合特性,变换域滤波方法难以构建完美的变化域滤波器,会造成相当大的目标能量损失;信号重构类方法则由于参数估计过程的复杂运算增加系统负担,影响实时性应用。

认知雷达系统的快速发展表明^[14],波形设计与相干信号积累^[15]是對抗频谱弥散干扰的有效途径。文献[16-17]专门针对频谱弥散干扰场景开展了认知波形设计研究,其重点在于降低发射波形的自相关旁瓣并最小化干扰信号与匹配滤波器之间的互相关特性。在上述方法中,作者在主分量最小化(Majorization-Minimization, MM)算法框架^[18]下简化并求解相应的优化问题,实现了波形域的频谱弥散干扰对抗。此外,文献[19]进一步将波形设计与稀疏分解方法相结合,以压制频谱弥散干扰分量在接收机中产生的密集虚假目标。为进一步提升干扰抑制性能,文献[20]研究了发射波形与时空

接收滤波器的联合优化方法,以同时降低干扰信号的自相关旁瓣电平与互相关峰值,并提出了一种迭代惩罚方法来解决抗干扰波形设计过程中的非凸优化问题。

为了充分发挥多脉冲高自由度设计优势,在文献[21]中,作者基于多相编码频率调制(Poly-phase Coded Frequency Modulation, PCFM)波形体制,提出一种基于多脉冲互补波形设计方法,有效解决了硬件资源受限条件下优化波形难以高保真发射问题。然而,PCFM波形体制的高保真发射特性以牺牲波形设计自由度为代价,限制了复杂电子对抗条件下的干扰对抗性能。

针对频谱弥散干扰对抗难题,本文提出一种波形域主动式干扰对抗方法,该方法能够通过多脉冲联合互补设计增大波形域抗干扰自由度。在具体实现过程中,首先在频谱弥散干扰分量能量最小化以及多脉冲互补脉压最小化准则下建立目标函数;在此基础上,进一步引入多脉恒模约束条件,以构建用于频谱弥散干扰对抗的多脉冲联合互补设计模型。最后,提出一种基于共轭梯度下降的多脉冲求解方法,实现了对频谱弥散干扰的有效对抗。

1 问题建模

本节首先介绍了频谱弥散干扰的作用原理,然后给出了多脉冲发射条件下的干扰参数化模型。在此基础上,进一步建立了恒模约束条件下的多脉冲互补设计模型。

1.1 频谱弥散干扰参数化建模

图1所示为频谱弥散干扰工作原理示意图,其中 T_p 表示发射波形时域宽度, L 表示子脉冲个数。在实际工作过程中,雷达系统首先向工作空间中辐射脉冲信号,在频谱弥散干扰机检测到雷达信号的上升沿后,干扰机开始截获、存储雷达信号;随后,干扰机对截获的雷达信号进行降采样处理,以获得干扰子脉冲信号;最后,干扰机对干扰子脉冲进行延迟及拼接处理,以获得在时域上与雷达波形等宽的频谱弥散干扰分量。在上述工作过程中,降采样处理能够使得干扰分量在频域进行扩

展,进而确保对目标信号进行频谱遮蔽;而复制拼接处理,可以增大接收机中的干扰能量,增强干扰效果。由于频谱弥散干扰分量与雷达发射波形密切相关,雷达接收端在进行相参累积处理时同样会对干扰能量进行累积,进而产生大量的梳状假目标,对真实目标的探测产生严重影响。




图1 频谱弥散干扰工作原理示意图

根据以上分析,频谱弥散干扰对其截获波形的调制及变换处理是一个线性变换过程,因而干扰分量与雷达发射波形具备以下线性关系

$$\mathbf{s}^J = \mathbf{J}_{\text{SMSP}} \cdot \mathbf{s} \quad (1)$$

式中, $\mathbf{s}$ 表示长度为 N 的雷达发射波形, $\mathbf{J}_{\text{SMSP}}$ 为变换矩阵,用于表示频谱弥散干扰机对截获波形的变换处理, $\mathbf{s}^J$ 表示相应得到的频谱弥散干扰分量。根据频谱弥散干扰分量的产生原理,变换矩阵 $\mathbf{J}_{\text{SMSP}}$ 可以表示为

$$\mathbf{J}_{\text{SMSP}} = [\mathbf{I}_{\text{SMSP}}, \dots, \mathbf{I}_{\text{SMSP}}]_{N \times N} \quad (2)$$

其中,矩阵分量 $\mathbf{I}_{\text{SMSP}}$ 可以进一步表示为

$$\mathbf{I}_{\text{SMSP}} = \begin{bmatrix} \underbrace{1 \ 0 \ \dots \ 0}_M & & \\ & \ddots & \\ & & \underbrace{1 \ 0 \ \dots \ 0}_M \end{bmatrix}_{N \times N} \quad (3)$$

其中, $\bar{N}$ 表示频谱弥散干扰的子脉冲长度, M 表示频谱弥散干扰的降采样因子。在频谱弥散干扰分量与雷达发射波形时域采样长度一致时,干扰机降采样因子与子脉冲个数数值一致,即有

$$M = L = \frac{N}{\bar{N}} \quad (4)$$

1.2 多脉冲互补设计模型

假定雷达系统发射 K 个互补脉冲,则根据公式(1)所示的波形与干扰分量关系,雷达发射的第 k 个脉冲对应的干扰分量可以表示为

$$\mathbf{s}_k^J = \mathbf{J}_{\text{SMSP}} \cdot \mathbf{s}_k, k = 1, \dots, K \quad (5)$$

式中, $\mathbf{s}_k$ 表示系统发射的第 k 个脉冲, $\mathbf{s}_k^J$ 表示对应的频谱弥散干扰分量。在雷达接收端,经过匹配滤波处理后,干扰分量 $\mathbf{s}_k^J$ 对应的脉压结果具有以下表达式:

$$\mathbf{r}_k^J = \mathbf{F}^H \left[(\mathbf{F} \cdot \bar{\mathbf{s}}_k) \odot (\mathbf{F} \cdot \bar{\mathbf{s}}_k^J)^* \right] \quad (6)$$

式中, $\bar{\mathbf{s}}_k = [\mathbf{s}_k^T, \mathbf{0}_{1 \times (N-1)}]^T$ 表示发射波形补零后结果, $\bar{\mathbf{s}}_k^J = [(\mathbf{s}_k^J)^T, \mathbf{0}_{1 \times (N-1)}]^T$ 表示干扰分量补零后结果, $\mathbf{F}$ 表示离散傅里叶变换(Discrete Fourier Transform, DFT)矩阵, $(\cdot)^H$ 表示共轭转置运算, $(\cdot)^*$ 表示取共轭, $\odot$ 表示哈达玛乘积。

由公式(6)可知,由于干扰分量与发射波形具有一定的相参性,接收端经匹配滤波处理后干扰分量会实现能量累积,进而产生虚假目标,对真实目标形成遮蔽效应。为了实现对假目标抑制,可以通过波形设计手段,压制脉压结果中的各个距离单元响应,从而实现干扰抑制。然而,单脉冲设计时参数自由度有限,无法在强对抗环境下实现对干扰的有效抑制。对此,本文以多脉冲互补设计思路,通过协同多脉冲参数,扩展频谱弥散干扰对抗自由度,进而提升波形域干扰对抗自由度。

对于发射 K 个互补脉冲的雷达系统,干扰机对截获的雷达波形分别进行调制及转发处理。在雷达接收端,对应于 K 个发射脉冲的干扰互补脉压结果可以表示为

$$\mathbf{r}^J = \sum_{k=1}^K \mathbf{F}^H \left[(\mathbf{F} \cdot \bar{\mathbf{s}}_k) \odot (\mathbf{F} \cdot \bar{\mathbf{s}}_k^J)^* \right] \quad (7)$$

由上式可知, K 个干扰分量经过相应的脉压处理后,以相参叠加的方式进行累积处理。通过合理选择波形参数,各个干扰分量的脉压响应可以相互抵消,进而实现更优的干扰抑制性能。

为了兼顾干扰对抗与目标探测性能,波形脉压低旁瓣同样是波形域抗干扰过程中需要实现的重要性能。与公式(7)相似, K 个发射波形的互补脉压结果可以表示为

$$\mathbf{r} = \sum_{k=1}^K \mathbf{F}^H \left[(\mathbf{F} \cdot \bar{\mathbf{s}}_k) \odot (\mathbf{F} \cdot \bar{\mathbf{s}}_k)^* \right] \quad (8)$$

同样,通过合理选择波形参数,各个发射波形的脉压旁瓣相互抵消,而脉压主瓣恒定为 KN ,因而实现更优的脉压低旁瓣性能。在实际应用中,

为了保证雷达发射机始终处于最大效率状态,还需对发射波形的幅度范围施加一定约束,常见的约束包括恒模约束与峰均功率比约束。联合考虑公式(7)和公式(8)所示的干扰互补脉压结果与波形互补脉压结果,最终可以建立以下用于频谱弥散干扰对抗的多脉冲互补设计模型:

$$\begin{aligned} \min_{s_1, \dots, s_K} f(s_1, \dots, s_K) \\ \text{s.t. } |s_k(n)| = 1, n = 1, \dots, N, k = 1, \dots, K \end{aligned} \quad (9)$$

式中, $s(n)$ 表示波形矢量 s 的第 n 个元素, 函数分量

$$\begin{aligned} f(\cdot) &= f_1(\cdot) + f_2(\cdot) \\ f_1(s_1, \dots, s_K) &= \|r'\|_p^2 \\ f_2(s_1, \dots, s_K) &= \|r \odot w_{sl}\|_p^2 \end{aligned} \quad (10)$$

分别表示干扰分量互补脉压响应以及波形分量互补脉压响应的旁瓣值, $\|\cdot\|_p$ 表示 p 范数。通过求解以上多脉冲互补设计模型, 即可获取兼顾干扰对抗与目标探测性能的互补脉冲。

2 求解算法

由于恒模约束存在, 上述建立的抗干扰多脉冲互补设计模型是一个典型的非凸优化模型, 难以在多项式时间内进行求解。针对这一求解难题, 本文提出一种基于相位梯度法的最优波形求解算法, 利用迭代求解策略, 获取兼顾干扰对抗与目标探测的互补波形。

2.1 算法基本框架

取公式(9)中各个优化变量的相位, 则原始关于波形变量的恒模约束问题可以转化为以下关于相位变量的优化问题

$$\begin{aligned} \min_{\alpha_1, \dots, \alpha_K} f(\alpha_1, \dots, \alpha_K) \\ \text{s.t. } 0 \leq \alpha_k(n) \leq 2\pi, n = 1, \dots, N \end{aligned} \quad (11)$$

对于需要设计的相位矢量 $\alpha_1, \dots, \alpha_K$, 为了简化优化求解过程, 可以通过以下堆叠处理, 将多个矢量优化变量转化为相位矩阵优化变量

$$X = \begin{bmatrix} \alpha_1(1) & \cdots & \alpha_K(1) \\ \vdots & & \vdots \\ \alpha_1(N) & \cdots & \alpha_K(N) \end{bmatrix}_{N \times K} \quad (12)$$

基于梯度下降策略, 相位矩阵的更新过程可

以表示为

$$X_{t+1} = X_t + \beta_{t+1} \cdot D_{t+1} \quad (13)$$

式中, X 表示第 $t+1$ 次迭代时的相位矩阵, β_{t+1} 表示相应的下降步长, 可以通过线搜索方式进行确定。此外, D_{t+1} 表示第 $t+1$ 次迭代时的下降方向, 通常由目标函数梯度以及目标函数的海森矩阵确定。大量工作表明, 利用目标函数梯度以及前一次的下降方向共同确定 D_{t+1} , 能够平衡计算复杂度与波形优化性能。此时, 下降方向 D_{t+1} 可以表示为

$$D_{t+1} = -\nabla f(X_{t+1}) + \gamma_t \cdot D_t \quad (14)$$

其中, $\nabla f(X_{t+1})$ 表示目标函数关于相位矩阵的梯度, γ_t 表示组合系数, 可以通过 Hestenes-Stiefel 公式更新。

2.2 目标函数梯度

在利用公式(13)所示的更新准则求解所需抗干扰波形时, 需在每次迭代时计算目标函数的梯度值 $\nabla f(X_{t+1})$ 。根据梯度计算线性运算准则, 目标函数关于相位矢量 X 的梯度可以计算为

$$\nabla f(X) = \nabla f_1(X) + \nabla f_2(X) \quad (15)$$

式中,

$$\nabla f_1(X) = \frac{\partial}{\partial X} \|r'\|_p^2 \quad (16)$$

$$\nabla f_2(X) = \frac{\partial}{\partial X} \|r \odot w_{sl}\|_p^2 \quad (17)$$

分别表示函数分量 $f_1(\cdot)$ 和 $f_2(\cdot)$ 关于相位矢量的梯度函数。进一步结合公式(7), 函数分量 $f_1(\cdot)$ 关于 $\alpha_k(n)$ 的梯度可以计算为

$$\begin{aligned} \frac{\partial}{\partial \alpha_k(n)} f_1(X) &= \frac{\partial}{\partial \alpha_k(n)} \|r'\|_p^2 = \\ &= \frac{\partial}{\partial \alpha_k(n)} \left(|r'|^p \right)^{\frac{2}{p}} = \\ &= \frac{2}{p} \left(|r'|^p \right)^{\frac{2}{p}-1} \mathbf{1}^T \frac{\partial |r'|^p}{\partial \alpha_k(n)} \end{aligned} \quad (18)$$

其中, $\mathbf{1}$ 表示取值全部为1的列向量。

$$\begin{aligned} \frac{\partial |r'|^p}{\partial \alpha_k(n)} &= \frac{\partial}{\partial \alpha_k(n)} \left(r' \odot (r')^* \right)^{\frac{p}{2}} = \\ &= p |r'|^{p-2} \odot \text{Re} \left(\frac{\partial r'}{\partial \alpha_k(n)} \odot (r')^* \right) \end{aligned} \quad (19)$$

其中, $\text{Re}(\cdot)$ 表示实部操作。对上式中的互补脉压

结果 r^J 求偏导数, 可得

$$\begin{aligned} \frac{\partial r^J}{\partial \alpha_k(n)} &= \frac{\partial}{\partial \alpha_k(n)} \sum_{k=1}^K F^H \left[(F \cdot \bar{s}_k) \odot (F \cdot \bar{s}_k^J)^* \right] = \\ &F^H \left[\left(F \cdot \frac{\partial}{\partial \alpha_k(n)} \bar{s}_k \right) \odot (F \cdot J \cdot \bar{s}_k)^* \right] + \\ &F^H \left[(F \cdot \bar{s}_k) \odot \left(F \cdot J \cdot \frac{\partial}{\partial \alpha_k(n)} \bar{s}_k \right)^* \right] \quad (20) \end{aligned}$$

由于 $s_k = \exp(j\alpha_k)$, 可得

$$\begin{aligned} \frac{\partial}{\partial \alpha_k(n)} s_k &= \frac{\partial}{\partial \alpha_k(n)} \exp(j \cdot \alpha_k) = \\ j s_k \odot \frac{\partial}{\partial \alpha_k(n)} \alpha_k &= j s_k \odot \mathbf{1}_n \quad (21) \end{aligned}$$

其中, $j^2 = -1$ 表示单位虚数, $\mathbf{1}_n$ 表示第 n 个元素取值为 1 的列向量。对公式(21)两边分别进行补零处理, 可得

$$\frac{\partial}{\partial \alpha_k(n)} \bar{s}_k = j \bar{s}_k \odot \bar{\mathbf{1}}_n \quad (22)$$

其中, $\bar{\mathbf{1}}_k = [\mathbf{1}_k^T, \mathbf{0}_{1 \times (N-1)}]^T$ 。将公式(22)代入公式(20), 进一步联立公式(18)和公式(19), 可得函数分量 $f_1(\cdot)$ 关于相位矢量的梯度为

$$\begin{aligned} \frac{\partial}{\partial \alpha_k(n)} f_1(X) &= 2 \left(\mathbf{1}^T |r^J|^p \right)^{\frac{2}{p}-1} \bar{\mathbf{1}}_n^T \times \\ &\text{Im} \left\{ \left(F^H F \left(F \left(|r^J|^{p-2} \odot r^J \odot (F \cdot \bar{s}_k)^* \right) \right)^* \right) \odot \right. \\ &\left. \bar{s}_k^* - \left(F^H \left[F \left(|r^J|^{p-2} \odot r^J \odot (F \cdot \bar{s}_k) \right) \right] \odot \bar{s}_k^H \right) \right\} \quad (23) \end{aligned}$$

同理可得,

$$\begin{aligned} \frac{\partial}{\partial \alpha_k(n)} f_2(X) &= 2 \left(w_{\text{SL}}^T |r^J|^p \right)^{\frac{2}{p}-1} \bar{\mathbf{1}}_n^T \times \\ &\text{Im} \left\{ \left(F^H \left(F \left(w_{\text{SL}} \odot |r^J|^{p-2} \odot r^J \odot (F \cdot \bar{s}_k)^* \right) \right)^* \right) \odot \bar{s}_k^* - \right. \\ &\left. \left(F^H \left[F \left(w_{\text{SL}} \odot |r^J|^{p-2} \odot r^J \odot (F \cdot \bar{s}_k) \right) \right] \odot \bar{s}_k^H \right) \right\} \quad (24) \end{aligned}$$

联立公式(23)和公式(24), 可得目标函数 $f(X)$ 关于相位矢量 α_k 的偏导数。因而可以根据公式(14)计算每次迭代时的下降方向。

2.3 算法总结与复杂度分析

表1给出了所提算法的主要步骤, 通过循环执

行步骤1至步骤4, 可以逐渐更新互补波形的相位矩阵。随后, 利用相位矩阵与互补波形的映射关系, 可以获取优化后的抗干扰互补波形。

表1 抗干扰互补脉冲设计算法迭代步骤

输入: 干扰参数 J , 初始化相位矩阵 X_0 , 算法最大迭代次数 T , 编码长度 N , 互补脉冲数 K
输出: 抗干扰互补波形集 $s_1, s_2, \dots, s_K$

当 $t = 1, 2, \dots, T$ 时, 执行

步骤1: 根据公式(15)计算目标函数梯度;

步骤2: 根据公式(14)计算下降方向;

步骤3: 搜索迭代步长 β_t ;

步骤4: 根据公式(13)更新相位矢量;

直至收敛, 输出 X_T ;

步骤5: 根据公式(12)计算输出最优互补波形集。

在表1中, 所提方法的计算复杂度与算法总体迭代次数 T 呈线性关系。在每次迭代中, 计算复杂度主要取决于目标函数以及梯度函数的计算过程。其中, 每次计算均涉及到对 K 个相位矢量求偏导。由于求偏导的计算过程涉及到 DFT 运算, 相位矢量的计算复杂度可以近似为 $\mathcal{O}(N \log N)$ 。因此, 算法的整体计算复杂度可以近似为 $\mathcal{O}(TMN \log N)$ 。

3 实验与结果分析

本节通过数值仿真与电磁计算数据, 对所提互补波形设计方法的频谱弥散干扰对抗性能进行检验。实验中, 首先对所提算法的收敛性能进行检验, 然后在点目标探测场景下检测波形性能。最后, 进一步基于典型车辆目标的电磁计算数据, 检验优化波形在扩展目标探测场景下的频谱弥散干扰对抗性能。

3.1 算法收敛性分析

本节基于数值仿真实验, 对表1中所示算法的收敛性能进行检验。实验过程中, 互补波形个数设置为 $K = 3$, 波形编码长度为 $N = 128$, 波形设计模型阶数 p 设置为 2, 算法最大迭代次数设置为 $T = 5000$ 。对于频谱弥散干扰参数, 干扰机降采样因子及子脉冲个数均设置为 4。图2给出了所提算法输出归一化损失函数值随算法迭代次数的变化曲线。由图可知, 随着算法迭代的进行, 用于互补波

形设计的损失函数值单调下降。此外,随着迭代次数的不断加深,损失函数下降速率不断减缓,表明算法逐渐趋向于模型稳定点,表明了所提算法的有效性。




图2 损失函数随迭代次数变换曲线


为了进一步检验不同互补脉冲数条件下所设计波形的脉冲压缩性能与频谱弥散干扰对抗性能,图3给出了发射波形与频谱弥散干扰的互补脉压结果。其中,波形编码长度设置为256,波形设计模型阶数 p 设置为10,算法最大迭代次数设置为 $T = 5000$,干扰降采样因子设置为8,互补脉冲数分别设置为1,3,5,10。

图3(a)给出了不同互补脉冲数条件下发射波形的互补脉压结果。由图可知,所设计的波形在零时延处具有高的脉压峰值,而在旁瓣区域具有低响应值。此外,随着互补脉冲数目的不断增加,波形互补脉压的旁瓣水平也在不断降低。当互补脉冲数从 $K = 1$ 增加到 $K = 10$ 时,互补脉压旁瓣水平降低了25 dB以上。图3(b)给出了不同互补脉冲数条件下频谱弥散干扰的互补脉压结果。由图可知,随着互补脉冲数的逐渐增加,干扰响应水平由-46 dB下降至-85 dB左右,干扰抑制性能逐渐增强。


3.2 干扰条件下点目标探测实验

本节基于数值仿真数据,开展点目标场景下的抗干扰波形性能验证实验。实验中,发射波形脉冲宽度设置为 $2.56 \mu\text{s}$,采样率设置为100 MHz,互补脉冲数设置为 $K = 3$,模型阶数设置为 $p = 10$,两点目标位置分别设置为5.0 km与5.2 km,干扰子脉冲个数设置为8,信干比设置为-30 dB,其余波

形设计算法参数与上节实验保持一致。




(a) 发射波形互补脉压结果




(b) 干扰分量互补脉压结果

图3 发射波形与频谱弥散干扰的互补脉压结果


为了表明所设计波形在干扰对抗方面的优势,图4(a)和(b)分别给出了利用LFM波形进行探测时的脉压结果。由图可知,当探测环境理想且不存在干扰时,实验预设目标清晰可见。当环境中存在频谱弥散干扰时,干扰分量会产生大量的梳状假目标,峰值旁瓣比达到-5 dB左右,对真实目标形成欺骗及压制效果,无法发现真实目标。为了进一步说明所提算法的频谱弥散干扰对抗性能,图4(c)给出了利用本文所提算法设计的抗干扰波形目标探测的实验结果。同时,为了进一步展示所提算法优势,图4(d)和(e)给出了传统接收端处理类方法中基于变换域滤波的抗干扰方法^[7]、发射端处理类方法中基于波形设计的抗干扰方法^[20]的实验结果。由图4(c)可知,对含干扰回波进行互补脉压处理后,干扰形成的假目标被有效抑制,脉压旁瓣水平被压制到-30 dB左右,预设目标清晰可见,表明了所提方法在频谱弥散干扰抑制方面的优势。而在对比算法中,由于干扰与目标




(a) 无干扰场景下 LFM 波形探测结果




(b) 含干扰场景下 LFM 波形探测结果



(c) 基于信号重构的干扰抑制方法



(d) 基于波形设计的干扰抑制方法



(e) 本文所提方法

图4 点目标场景下不同波形探测结果

耦合特性,变换域滤波方法无法有效清除干扰影响,滤波后的干扰残余使得脉压结果达 -20 dB左右,效果有限。同时,由于波形设计方法中没有发挥多脉冲联合设计效能,干扰对抗效果也弱于本文所提算法。

3.3 干扰条件下扩展目标探测实验

为了进一步展示所提互补波形设计算法对频谱弥散干扰的对抗性能,本节基于典型空间目标电磁计算数据开展干扰条件下的扩展目标探测实验。

实验过程中,首先建立典型空间卫星目标的计算机辅助设计(Computer-Aided Design, CAD)模型,然后利用电磁仿真计算软件计算目标在不同频点、不同方位、以及不同俯仰条件下的雷达散射截面(Radar Cross Section, RCS)。在实验过程中,将不同的发射波形与计算得到的 RCS 数据进行结合,即可得到相应的空间目标回波数据。随后,基于匹配滤波处理准则,即可得到空间目标的脉压结果。在 RCS 计算过程中,以 100 MHz 为频率间隔,分别计算 $9\sim 11$ GHz 的目标全姿态频率响应值。发射波形参数与干扰参数如前述实验保持一致,抗干扰波形设计算法参数保持不变。图 5 所示为目标 CAD 模型。

如图 6 所示为不同波形体制下的扩展目标探测结果。对比图 6(a)和(b)可知,由于干扰存在,脉压旁瓣水平得到抬升,目标散射点被干扰形成的假目标遮蔽,严重破坏了观测目标的结构信息。图 6(c)所示为基于抗干扰波形的扩展目标探测结







图5 空间卫星目标的CAD模型



(a) 无干扰场景下 LFM 波形探测结果



(b) 含干扰场景下 LFM 波形探测结果



(c) 含干扰场景下抗干扰波形探测结果

图6 扩展目标场景下不同波形探测结果

果。对比图6(b)和(c)可知,抗干扰波形能够破坏频谱弥散干扰在接收端的能量累积过程,进而对

假目标形成压制,使得扩展目标脉压结果中的散射点清晰可见。因而,所提方法实现了对频谱弥散干扰的有效抑制。

4 结束语

本文围绕雷达有源转发方式干扰对抗需求,针对脉冲多普勒雷达系统面临的频谱弥散干扰对抗难题,提出一种基于多脉冲互补波形设计的干扰对抗方法。在具体实现过程中,首先根据频谱弥散干扰的形成机理,建立了多脉冲互补波形设计模型;随后提出了基于相位梯度法的最优波形求解算法;最后,通过数值仿真实验验证算法的有效性,在此基础上基于典型空间目标电磁计算数据开展干扰条件下的扩展目标探测实验,抗干扰波形能够破坏频谱弥散干扰在接收端的能量累积过程,对假目标形成压制,实现对频谱弥散干扰的有效抑制。

本文对频谱弥散干扰抑制波形进行了设计与验证,主要针对静态场景下的干扰对抗需求开展研究,而实际对抗场景中雷达与干扰机常常处于动态对抗条件,因此可以进一步结合博弈论相关知识,研究博弈对抗条件下的抗干扰波形决策方法提升算法的应用能力。此外,后续研究还应当充分考虑实际雷达系统的硬件资源约束,进一步探索兼顾干扰对抗与目标探测的最优波形高效设计方法以实现应用效能。

参考文献:

- [1] 董乔龙,刘思琪,张伟见,等.LFM-DPC抗间歇采样转发干扰波形集设计算法[J].系统工程与电子技术,2025,47(7):2154-2164.
- [2] 张云,姚慧雨,张倩,等.SAR抗转发式干扰波形设计与优化[J].哈尔滨工业大学学报,2024,56(9):17-30.
- [3] 余涛,周正春,杜小勇,等.一种基于完全互补码波形设计的抗间歇式采样转发干扰方法[J].电子与信息学报,2023,45(11):3896-3905.
- [4] QIU Xiangfeng, ZHANG Xinyu, JIANG Weidong, et al. Transmit - Receive Joint Optimization Method for Target Measurement Under Interrupted Sampling Repeater Jamming Scenarios[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-18.

- [5] QIU Xiangfeng, JIANG Weidong, LIU Yongxiang, et al. Learning-Enhanced Riemannian Gradient Descent Method for Transmit-Receive Joint Design Toward ISRJ Suppression[J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(3): 6265-6279.
- [6] QIU Xiangfeng, JIANG Weidong, LIU Yongxiang, et al. Constrained Riemannian Manifold Optimization for the Simultaneous Shaping of Ambiguity Function and Transmit Beam pattern [J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(3): 5771-5787.
- [7] HANBALI S B S. Countering Self-Protection Smeared Spectrum Jamming Against Chirp Radars[J]. IET Radar, Sonar & Navigation, 2021, 15(4): 382-389.
- [8] ZHANG Yongxiang, DING Kai. Research on SMSJP Jamming Suppression Based on Matched Filtering in FrFT Domain[C]//2024 7th International Conference on Computer Information Science and Application Technology, Hangzhou, China: IEEE, 2024: 963-966.
- [9] 赵杨, 尚朝轩, 韩壮志, 等. 分数阶傅里叶和压缩感知自适应抗频谱弥散干扰[J]. 电子与信息学报, 2019, 41(5): 1047-1054.
- [10] WU Chuanzhang, CHEN Baixiao, YANG Minglei, et al. A Study on Parameter Estimation and Suppression for Smeared Spectrum Jamming Based on Short-Time Fourier Transform[J]. EURASIP Journal on Wireless Communications and Networking, 2020(6): 1-16.
- [11] WANG Xiaoge, CHEN Hui, ZHU Yongzhe, et al. SMSJP Interference Suppression Method Based on Time-Domain Interference Matching[C]//IET International Radar Conference, Chongqing, China: IEEE, 2023: 991-997.
- [12] WANG Xiaoge, CHEN Hui, LIU Weijian, et al. ECCM Scheme Against SMSJP Interference Based on Interference Reconstruction[C]//2024 IEEE 6th Advanced Information Management, Communication, Electronic and Automation Control Conference, Chongqing, China: IEEE, 2024: 161-167.
- [13] WAN Pengfei, LIAO Guisheng, XU Jingwei, et al. SMSJP Mainlobe Jamming Suppression with FDA-MIMO Radar Based on FastICA Algorithm[J]. Sensors, 2023, 23(12): 5619.
- [14] STINCO P, GRECO M, GINI F, et al. Cognitive Radars in Spectrally Dense Environments[J]. IEEE Aerospace and Electronic Systems Magazine, 2016, 31(10): 20-27.
- [15] WANG Mingxing, LI Xiaolong, GAO Longji, et al. Multichannel Signal Integration Approach for High-Speed Target Detection in Coherent MIMO Radar System[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(5): 8298-8315.
- [16] LU Shuping, CUI Guolong, YI Wei, et al. Radar Waveform Design Against Signal-Dependent Jamming[C]//2017 IEEE Radar Conference, Seattle, WA, USA: IEEE, 2017: 1075-1080.
- [17] LU Shuping, CUI Guolong, YU Xianxiang, et al. Cognitive Radar Waveform Design Against Signal-Dependent Modulated Jamming[J]. Progress in Electromagnetics Research B, 2018, 80: 59-77.
- [18] QIU Xiangfeng, YANG Chen, JIANG Weidong, et al. Joint Design of Transmit Waveform and Receive Filter for Cross Ambiguity Function Synthesis[J]. IEEE Wireless Communications Letters, 2024, 13(3): 839-843.
- [19] JIANG Tao, YU Leixin, XING Jiangnan, et al. Dictionary Learning and Waveform Design for Dense False Target Jamming Suppression[J]. Applied Computational Electromagnetics Society, 2021, 36(9): 1173-1181.
- [20] ZUO Lei, LAN Zhengyu, LU Xiaofei, et al. Joint Transmit-Receive Filter Design with Lower APSL and ICPL to Suppress Interference[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(3): 3673-3687.
- [21] QIU Xiangfeng, JIANG Weidong, ZHANG Xinyu, et al. Design of Complementary PCFM Waveform Set for Smearing Spectrum Jamming Suppression in MIMO Radar Systems[J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(4): 10149-10168.

作者简介:

杨 贤(通信作者) 女, 硕士, 高级工程师, 主要研究方向为信号处理。



中国科技核心期刊

(中国科技论文统计源期刊)

收录证书

CERTIFICATE OF SOURCE JOURNAL
FOR CHINESE SCIENTIFIC AND TECHNICAL PAPERS AND CITATIONS

雷达科学与技术

经过多项学术指标综合评定及同行专家
评议推荐，贵刊被收录为“中国科技核心期
刊”（中国科技论文统计源期刊）。

特颁发此证书。

中国科学技术信息研究所

Institute of Scientific and Technical Information of China

北京复兴路 15 号 100038

www.istic.ac.cn

2024年9月



- 《中国学术期刊(光盘版)》全文收录期刊
- 《万方数据—数据化期刊群》入编期刊
- 《中文核心期刊要目总览》入编期刊
- 《中国学术期刊综合评价数据库》来源期刊
- 《中国核心期刊(遴选)数据库》收录期刊
- 《中文科技期刊数据库》收录期刊
- 《日本科学技术振兴机构数据库》收录期刊



雷达科学与技术

Leida Kexue yu Jishu
(双月刊 • 2003 年创刊)
2026 年 第 24 卷 第 1 期

Radar Science and Technology

(Bimonthly • Started in 2003)
Vol.24 No.1 2026

主管单位 中国电子科技集团公司

主办单位 中国电子科技集团公司第三十八研究所

编辑出版 《雷达科学与技术》编辑部

通信地址 安徽省合肥市 9023 信箱 60 分箱

邮政编码 230088

电 话 (0551) 65391270

电子信箱 radarst@163.com

网 址 <http://radarst.ijournal.cn>

印 刷 合肥添彩包装有限公司

发 行 《雷达科学与技术》编辑部

发行范围 国内外公开发行

Competent Authorities China Electronics Technology Group Corporation

Sponsored by The 38th Research Institute of
China Electronics Technology Group Corporation

Edited & Published by Editorial Department of Radar Science
and Technology

Address P.O.Box 9023-60, Hefei, China

Postcode 230088

Telephone (0551)65391270

E-mail radarst@163.com

Website <http://radarst.ijournal.cn>

Printed by Hefei Tiancai Packaging Co., Ltd.

Distributed by Editorial Department of Radar Science
and Technology

国际标准连续出版物号 ISSN 1672-2337

国内统一连续出版物号 CN 34-1264/TN

国内定价: 30.00 元 / 期
180.00 元 / 年