

全息凝视雷达低空目标探测数据集及多特征识别方法

田彪 陈俊彦* 万延煜 黄仕林 张月*

(中山大学电子与通信工程学院 广东深圳 518107)

摘要: 低空目标对机场等空域安全的威胁日趋显著,其精准探测与识别是雷达系统亟待解决的关键问题,而高质量的雷达实测数据集是推进低空目标识别的核心基础。然而,现有公开雷达低空目标数据集多为仿真数据或近距离采集数据,难以真实反映和验证远距离场景下雷达目标识别性能。因此,该文构建了基于全息凝视雷达(HSR)的低空目标探测识别数据集,完成了外场环境下典型低空目标的实测数据采集与识别验证。该数据集涵盖多旋翼无人机、雀类、大型迁徙鸟等典型目标,以及悬停、盘旋、径向飞行等典型运动场景,并且同步提供目标多普勒瀑布图与雷达实测航迹信息(含方位角、俯仰角、径向速度、归一化信噪比),为探索目标精细化特征与运动状态的内在关联提供了数据支撑。在此基础上,该文采用多模态自适应特征融合网络,提取不同目标的多普勒特征与运动学特征并进行融合,验证了区分不同类型低空目标的有效性。

关键词: 全息凝视雷达; 低空目标; 多普勒瀑布图; 数据集; 深度学习; 目标识别

中图分类号: TN957

文献标识码: A

文章编号: 2095-283X(2026)x-0001-19

DOI: 10.12000/JR25212

CSTR: 32380.14.JR25212

引用格式: 田彪, 陈俊彦, 万延煜, 等. 全息凝视雷达低空目标探测数据集及多特征识别方法[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR25212.

Reference format: TIAN Biao, CHEN Junyan, WAN Yanyu, *et al.* Low-altitude target dataset and multifeature recognition method based on holographic staring radar[J]. *Journal of Radars*, in press. doi: 10.12000/JR25212.

Low-altitude Target Dataset and Multifeature Recognition Method Based on Holographic Staring Radar

TIAN Biao CHEN Junyan* WAN Yanyu HUANG Shilin

ZHANG Yue*

(School of Electronics and Communication Engineering, Sun Yat-sen University Shenzhen, Guangdong 518107, China)

Abstract: The threat from low-altitude targets to airspace security such as airport is increasing, making accurate detection and recognition essential for radar systems. High-quality measured radar datasets are crucial for advancing low-altitude target recognition. However, most existing public radar datasets for these targets consist of simulation data or short-range collected data, which have difficulty accurately reflecting and verifying radar target recognition performance in long-range scenarios. To overcome these limitations, this study creates a low-altitude target detection and recognition dataset based on holographic staring radar, including measured data collection and recognition validation for typical low-altitude targets in outdoor environments. The dataset includes common targets such as multirotor unmanned aerial vehicles, sparrows, and large migratory birds,

收稿日期: 2025-10-27; 改回日期: 2026-04-27; 网络出版: 2026-xx-xx

*通信作者: 陈俊彦 chenjy655@mail2.sysu.edu.cn; 张月 zhangyue8@mail.sysu.edu.cn

*Corresponding Authors: CHEN Junyan, chenjy655@mail2.sysu.edu.cn; ZHANG Yue, zhangyue8@mail.sysu.edu.cn

基金项目: 国家自然科学基金(62371477, U2133216)

Foundation Items: The National Natural Science Foundation of China (62371477, U2133216)

责任编辑: 陈小龙 Corresponding Editor: CHEN Xiaolong

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License

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

along with representative motion scenarios like hovering, circling, and radial flight. It also offers synchronized target micro-Doppler waterfall plots and radar-measured track information (including azimuth and elevation angles, radial velocity, and normalized signal-to-noise ratio), providing a data foundation for exploring the intrinsic link between target detailed features and motion states. Building on this, a multimodal adaptive feature fusion network is developed to extract and combine Doppler and kinematic features from different targets, demonstrating the dataset's effectiveness in distinguishing various low-altitude targets.

Key words: Holographic Staring Radar (HSR); Low-altitude target; Doppler spectrogram; Dataset; Deep learning; Target recognition

1 引言

随着无人机技术的迅猛发展和全球生态环境的变化,低空目标正对现代空域安全与正常运行构成日益严峻的挑战^[1,2],主要体现在两个层面:一是以消费级无人机为代表的新型低空目标,在非法侦察、恐怖袭击、非对称作战等领域呈现巨大隐患;二是以鸟群为代表的目标,其活动对航空安全构成长期严重威胁,尤其是在机场近空区域,鸟击事件已成为航空器灾难的重要诱因^[3-5]。无论是无人机,还是鸟群,它们具有复杂的低空飞行行为、与地海杂波高度重叠的多普勒特征以及微弱的雷达散射截面(Radar Cross Section, RCS)等特性,使得传统雷达系统难以有效应对。因此,如何对低空目标进行有效的探测识别,已成为雷达技术、公共安全及航空保障领域亟待解决的重大技术和应用挑战^[6-8]。

为有效捕获低空目标特征,全息凝视雷达(Holographic Staring Radar, HSR)提供了一种全新探测体制方案。与传统扫描式窄波束雷达不同,HSR采用宽发窄收波束,实现了对整个监视空域的全时空覆盖^[9,10]。凝视工作模式下利用长时间相干积累技术,极大地提升了信号处理增益,使得探测RCS极低的目标成为可能。此外,在人工智能技术的强力驱动下,低空目标识别领域正经历着从传统信号处理到数据驱动方法的深刻转型,尤其是基于微多普勒(Micro-Doppler, MD)效应的精细化特征提取已成为研究焦点^[11-13]。微多普勒效应在时频域上会呈现出与目标物理结构和运动状态强相关的独特纹理和周期性结构,构成了目标的精细动态指纹。此外,引入能够反映目标宏观运动学行为的航迹信息,已成为提升识别性能的重要手段。已有研究表明,基于雷达航迹提取的速度、加速度、转弯特性等运动学特征能够有效区分鸟类与无人机;与此同时,微多普勒时频谱所表征的旋翼转动、扑翼周期等微观运动特征,在无人机/鸟类识别中具有较强判别力。此外,多维回波特征融合研究也表明,多源特征相比单一特征通常具有更高的识别精度和更好的鲁棒性,在低信噪比和高机动条件下,

将微多普勒估计与目标运动轨迹联合建模,有助于提升目标检测与分类的稳健性^[14-18]。因此,将宏观航迹特征与微多普勒所反映的微观结构动态进行联合建模,能够实现信息互补与相互印证,构建多维度、多层次的特征体系,从而提升目标识别的准确性、稳健性及复杂场景适应能力。

数据驱动的智能识别方法催生了对大规模、高保真实测数据集的迫切需求,以支撑先进算法的开发与验证。顺应这一趋势,国内外研究机构近年来着力构建并发布了一系列代表性工作。例如,LSS-FMCWR-1.0数据集^[19]利用Ku/L双波段雷达对多型无人机进行了实测,并提供了深度学习分类基线;在此基础上,LSS-PR-1.0被动雷达数据集^[20]则进一步将目标类型扩展至直升机、船只等,并引入了复杂的海洋环境杂波。这些高质量数据集的出现,有力地支撑了当前的主流技术范式:即将雷达回波转换为多普勒瀑布图、距离-多普勒谱图等二维图像,再利用卷积神经网络进行高效的特征提取与分类^[21]。尽管上述工作极大地丰富了领域内的数据资源并推动了识别技术发展,但深入分析可知,当前研究仍面临3个亟待解决的关键问题。首先,远距离、低信噪比的实测数据仍然不足。现有数据集的采集距离大多局限于数百米的近场范围,导致数据信噪比普遍偏高,未能真实反映远距离无人机及鸟类等目标探测的严苛条件。其次,针对新型雷达体制的专属数据存在空白。已有数据集大多基于调频连续波雷达或被动雷达,而对于HSR这类新体制系统,目前尚无公开的低空目标专属的大规模数据集予以支撑。最后,“特征-航迹”信息的深度融合研究尚不充分,当前研究高度集中于从多普勒瀑布图中提取目标的微观指纹,却在很大程度上忽略了由雷达自身同步测量且能够反映目标宏观行为意图的航迹信息^[22,23]。已有研究还指出,在远距离、小目标、低信噪比或鸟类滑翔等场景下,微多普勒特征可能弱化甚至不可见,此时需要引入运动等补充信息以维持识别性能。然而,针对HSR体制下由雷达同步输出的航迹量测与回波时频图进行帧级对齐、层级交互和自适应融合的研究仍较为匮乏。

为应对上述挑战, 本团队以自研的L波段HSR为平台, 开展了不同场景和场地的外场低空目标数据采集, 并在此基础上构建了面向该体制雷达的低空目标探测与识别数据集。本数据集的主要特色体现在:

(1) 真实复现远距离、低信噪比场景: 所有数据均采集于外场实测环境, 直面远距离探测带来的信号衰减、噪声与杂波干扰等现实挑战, 为开发和验证能够在实战条件下应用的鲁棒识别算法提供了高保真数据基础。

(2) 提供径向速度, 距离, 方位角, 高度, 归一化信噪比一体化的数据结构, 实现“特征-航迹”深度融合的一体化数据构建: 本数据集创新性地提供了多普勒瀑布图以及与雷达自身严格同步测量的航迹信息(本文称为航迹多普勒), 为算法开发验证提供更多输入条件。

2 数据采集及处理

2.1 全息凝视雷达简介

HSR采取独立的数字收发阵面, 不依赖传统雷达中机械或电子波束扫描过程, 而是通过宽波束发射与数字波束形成技术下多个窄波束接收, 实现对整个探测区域的连续探测。其中“全息”一词, 一方面是指对探测区域进行连续时空覆盖, 另一方面指雷达能够完整获取目标的多维信息, 包括距离、速度、角度以及多普勒信息等; 而“凝视”模式, 区别于传统扫描模式, 是指将波束持续固定指向同一空间区域, 对该区域进行连续探测的雷达工作模式。正是由于全息凝视探测, 瞬时目标容量较大, 各目标回波在时域上重叠, 必须依靠角度域和速度域才能对多目标进行联合分割, 该体制雷达存储的数据为目标检测后的分割数据。

HSR系统主要由天线阵列模块和软件化的信号处理平台两部分组成, 二者通过网络和光纤互联, 如图1所示。天线阵列模块包含发射机模块、接收机模块、时序控制与波束生成模块、频综模块以及电源模块等, 主要负责波束的发射与接收, 并将接收信号经由光纤传至信号处理平台; 信号处理平台接收来自天线阵列模块传递的数字信号, 并依次进行信号接收、通道校正、数字波束形成、长时间积累检测、点迹凝聚、目标关联跟踪与目标识别等处理。图1给出了雷达样机的系统架构。

HSR通过长时间相参处理提升弱小目标检测能力, 并细化多普勒分辨率, 实现对低空目标的有效探测。该雷达系统的主要技术参数如表1所示^[9]。

2.2 HSR数据处理流程

由于HSR采用的凝视体制, 可同时对覆盖范围内的多目标进行探测, 目标回波在时域上无法进行有效分割, 因此本数据集从雷达采集的原始多通道回波中, 生成可直接用于目标分析与算法训练的“航迹-特征”一体化信号: (1)连续目标航迹(含径向速度、距离、方位角、高度、归一化信噪比的时间序列); (2)与航迹对齐的多普勒瀑布图。雷达整体数据处理流程链路如图2所示。

针对全息雷达信号处理流程中的部分关键环节, 展开具体说明。

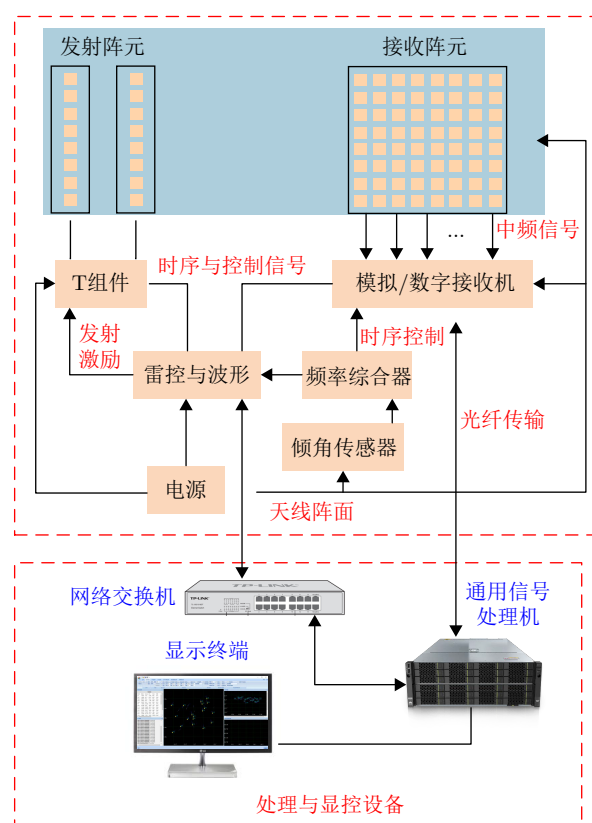


图1 全息凝视雷达样机系统架构

Fig. 1 System architecture of the holographic staring radar prototype and its display and control interface

表1 中山大学L波段全息雷达系统参数

Tab. 1 Basic parameters of the L-HSR developed by SYSU

参数名称	指标
频段	L波段
信号形式	线性调频
信号脉宽	2 μ s~20 μ s(根据目标距离切换)
信号带宽	2~16 MHz
PRF	~5 kHz
更新率	优于1 s

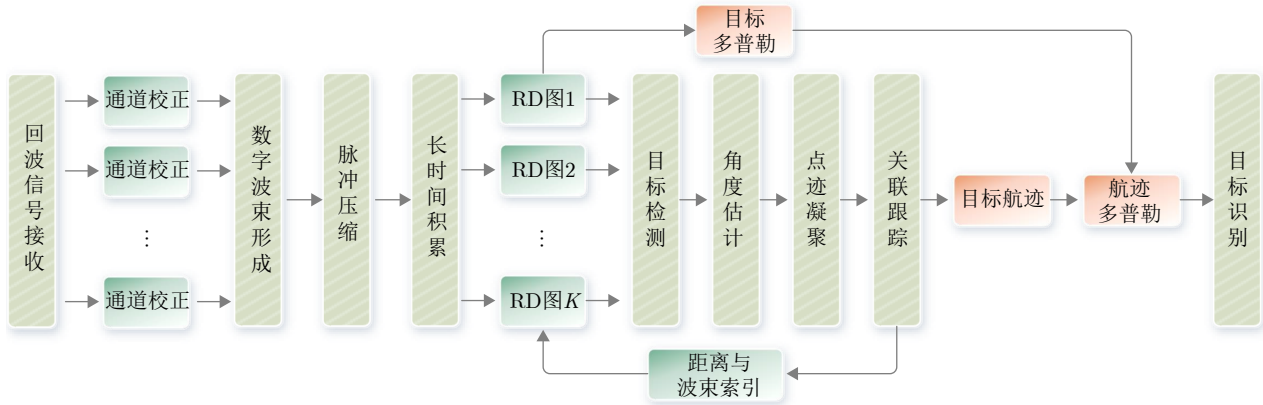


图2 数据处理流程

Fig. 2 Data processing pipeline

(1) 通道校正

HSR系统中, 模拟滤波器、放大器、下变频器等射频前端及模数转换器件本身会引起各接收通道幅相特性的失真和不一致性, 造成脉压旁瓣抬高, 天线方向图畸变等问题。本系统采用注入测试信号的方式对各通道的幅相特性进行测量, 生成校正系数, 并根据校正系数对各通道进行补偿。

(2) 波束形成

波束形成, 即通过对各接收通道进行加权合成, 为波束赋予特定的探测指向, 实现空域滤波。HSR采用单元级数字化, 再由信号处理对所有单元回波进行数字波束形成, 同时形成多个接收波束, 覆盖探测区域。由于接收波束指向固定, 波束形成算法实现较为简单, 但要求数字处理端具备强大的并行处理能力和数据传输带宽, 以满足同时多波束接收的要求。

(3) 长时间积累

各波束的回波数据经脉冲压缩处理后, 实现脉冲内能量积累。由于HSR采用低增益全向发射波束, 经过脉压后目标回波仍然较弱, 需通过脉冲间长时间积累来进一步提升信噪比, 以满足雷达探测要求。对于常规波束扫描雷达, 波束驻留时间有限, 可提供相干积累的脉冲数较少; 而对于HSR, 在探测区域内目标总会位于某个波束的照射范围, 更适合通过对多个脉冲周期的回波进行长时间相干处理来实现目标检测。每个相干处理间隔(Coherent Processing Interval, CPI)内的脉冲经过长时间积累处理后生成K个通道的距离-多普勒(Range-Doppler, RD)图像。

(4) 目标检测与角度估计

为提高目标检测性能, 在检测前需对RD图进行杂波抑制。由于静止背景杂波主要集中在多普勒频谱的低频区域, 因此在RD图的多普勒维度上引

入高通滤波器, 以有效抑制低频和静止杂波分量的影响, 同时保留由运动目标产生的高频多普勒信息。在完成杂波抑制后, 分别对每个RD图进行目标检测。HSR系统中采用恒虚警率(Constant False Alarm Rate, CFAR)检测方法, 通过对待检测单元邻域内的噪声与杂波功率进行统计估计, 自适应确定检测阈值。当待检测单元的回波能量超过所设定阈值时, 判定该单元内存在目标。此外, 针对低空目标角度估计时多径效应影响, 团队采用相干信号角度处理方法实现多径抑制^[24]。

(5) 点迹凝聚

在实测雷达系统中, 受雷达系统参数及目标尺寸等因素影响, 单个目标可能占据多个测量单元。因此, 通常需要通过点迹凝聚技术, 将多个相关联的点迹融合为单一目标点迹。在HSR系统中, 点迹凝聚根据径向速度、距离及角度等参数阈值, 对满足关联条件的多个回波点进行融合处理。

(6) 航迹关联与跟踪

通过航迹关联, 基于输入点迹结果生成目标航迹, 剔除虚警点迹。并且经过跟踪滤波处理, 进一步提升测量精度。

(7) 目标识别

在关联跟踪后, 雷达获得了观测区域内所有目标的距离、速度、方位角度和俯仰角度等航迹信息以及在比幅测角中所找到的幅度最大波束索引。利用关联跟踪后的最新航迹点距离索引和波束索引, 在对应波束RD图中相应距离单元内, 获取目标当前CPI的一维多普勒数据。将目标在不同CPI获得的一维多普勒谱按时间顺序进行拼接, 可构建目标的时间-多普勒(Time-Doppler, TD)二维矩阵, 即多普勒瀑布图。目标微多普勒在该瀑布图中呈现可判别的条纹结构, 是低空识别和人工标注的重要依据。与此同时, 结合目标关联跟踪输出的目标航迹

信息, 组合得到航迹多普勒数据, 作为本文识别模块输入的基础数据。

相较于传统RD图, 多普勒瀑布图具有明显优势, 尤其在针对低空目标精细化特征提取方面。(1)时序动态信息的可视化: RD图是单个CPI内的瞬时距离与速度(多普勒)的二维投影, 丢失了目标运动和微动特征的时间演化信息。而多普勒瀑布图是对连续慢时间序列进行多普勒分析结果, 将目标在径向速度维上的特征随时间的连续变化直观展示出来。(2)精细微动特征的捕获: 对于无人机旋翼、鸟类翅膀等微动部件, 在雷达回波上引起的多普勒调制具有周期性和非线性动态特征。多普勒瀑布图能够将这些微动特征(如条纹结构、周期、带宽等)以独特的时-频纹理清晰呈现出来, 这些纹理构成了目标的“精细动态指纹”, 是区分不同类型低空目标(如不同型号无人机、鸟类)的关键依据。实际采集记录过程中, 为了保证目标多普勒特征能够突显, 采用对数显示的方法对多普勒瀑布图进行增强。图3给出了不同目标的多普勒瀑布图, 图中横坐标为多普勒分辨单元数, 纵坐标为回波帧数。从图中可以看出, 不同目标的多普勒瀑布图具有一定差异。

(1) 多旋翼无人机: 其特征是围绕主体多普勒(对应机体运动速度)出现准周期性的垂直条纹, 并伴有由旋翼叶片周期性闪烁引起的梳状谐波边带。不同型号无人机的条纹周期和结构(如宽度、强度)存在一定差异。

(2) 鸟类目标: 雀类小型鸟类翼击频率高、扑动幅度小, 其微动条纹表现为细密且频率较高的特征。大型迁徙鸟类翼击周期更长、扑动幅度更大, 其微动条纹的周期较长, 且在多普勒频率上的跨度更宽。鸟群的多普勒瀑布图包含多个个体, 其回波能量在多普勒域上分布更宽, 且微动纹理的相干性显著降低, 整体结构较为杂乱。

(3) 地面目标: 地面固定旋转目标的瀑布图围绕零多普勒频带呈现出周期稳定、近乎对称的“蝶形”或条状结构。汽车的多普勒瀑布图的主能量带紧贴零多普勒频带并随其速度缓慢漂移, 偶尔可见由车轮或引擎引起的微弱低频调制。

3 数据集构建与初步分析

3.1 数据集构建

为构建全面且多样化的HSR目标航迹多普勒数据集, 本文利用L波段全息凝视雷达在深圳、长沙、重庆等城市城区、机场周边、郊区野外等不同场景与气象条件下进行了典型目标数据采集, 并将

该数据集命名为LSS-HSR-L。数据集涵盖的目标类型主要分为3类:

(1) 旋翼无人机: 包括大疆Air3, Mini3 Pro, Mavic 3e及Phantom 4 RTK, 为便于索引与使用, 在数据集中分别标记为UAV1, UAV2, UAV3和UAV4;

(2) 鸟类目标: 涵盖雀类小型鸟、鸟群及大型迁徙鸟, 为便于索引与使用, 在数据集中分别标记为Bird, Birds和Wing bird;

(3) 地物与干扰目标, 包括地面固定旋转目标和移动车辆, 为便于索引与使用, 在数据集中分别标记为Rotate和Car, 用以增强数据集的复杂性。

本数据集的标注体系遵循“物理属性→雷达观测量→时频域证据”的闭环, 确保每个标签都具备坚实的物理机理与数据支撑。考虑到雷达信号的核心可分信息蕴含于目标微多普勒上, 本数据集以高分辨率的多普勒瀑布图作为标注的核心视觉证据, 并辅以距离、角度、径向速度等航迹量测及信噪比统计进行交叉验证, 以保证标注的一致性。

为提升多普勒瀑布图的信噪比和可读性, 所有数据均经过了零频杂波抑制处理, 以消除静止地物及发射机泄漏的干扰。此外, 为确保标注结果的准确性与客观性, 团队设计了严格的标注质量控制流程。对于无人机类合作目标, 在飞行试验阶段即通过同步记录的飞控日志与视频, 预先获得了其精确的类别标签与航迹编号, 实现了“真值”先验获取。对于鸟类、汽车等非合作目标, 在无光电先验知识情况下, 采用“双人盲注-交叉验证”的策略。首先, 由两名经过统一标准培训的标注员在互不知晓对方结果的情况下, 对同一批数据进行独立标注。对于信噪比过低、特征间歇不可见或受多径严重遮蔽的样本, 标注员会将其明确标记为“不确定”类别, 并在后续流程中予以剔除。最终, 仅当两名标注员对同一个样本的标注结果完全一致时, 该样本的标签才被最终采纳, 以此最大限度地保证了数据集的标注质量。

最终数据集中, 每个数据样本由一段不同帧数组成的连续航迹构成, 各类别样本数量约为100个。为便于使用者调用与管理, LSS-HSR-L数据集采用了层级分明的组织结构, 如图4所示。其顶层目录包含Train和Validation两个子目录, 分别存放训练集与验证集。在每个子目录内, 数据按上述9个目标类别分置于独立的文件夹中, 文件夹名称即为该类别的标签。此外, 为降低文件读取及数据预处理难度, 本团队已将单个样本文件按照“样本序号_航迹长度.mat”的格式进行标准化命名, 使读者能够便捷使用。

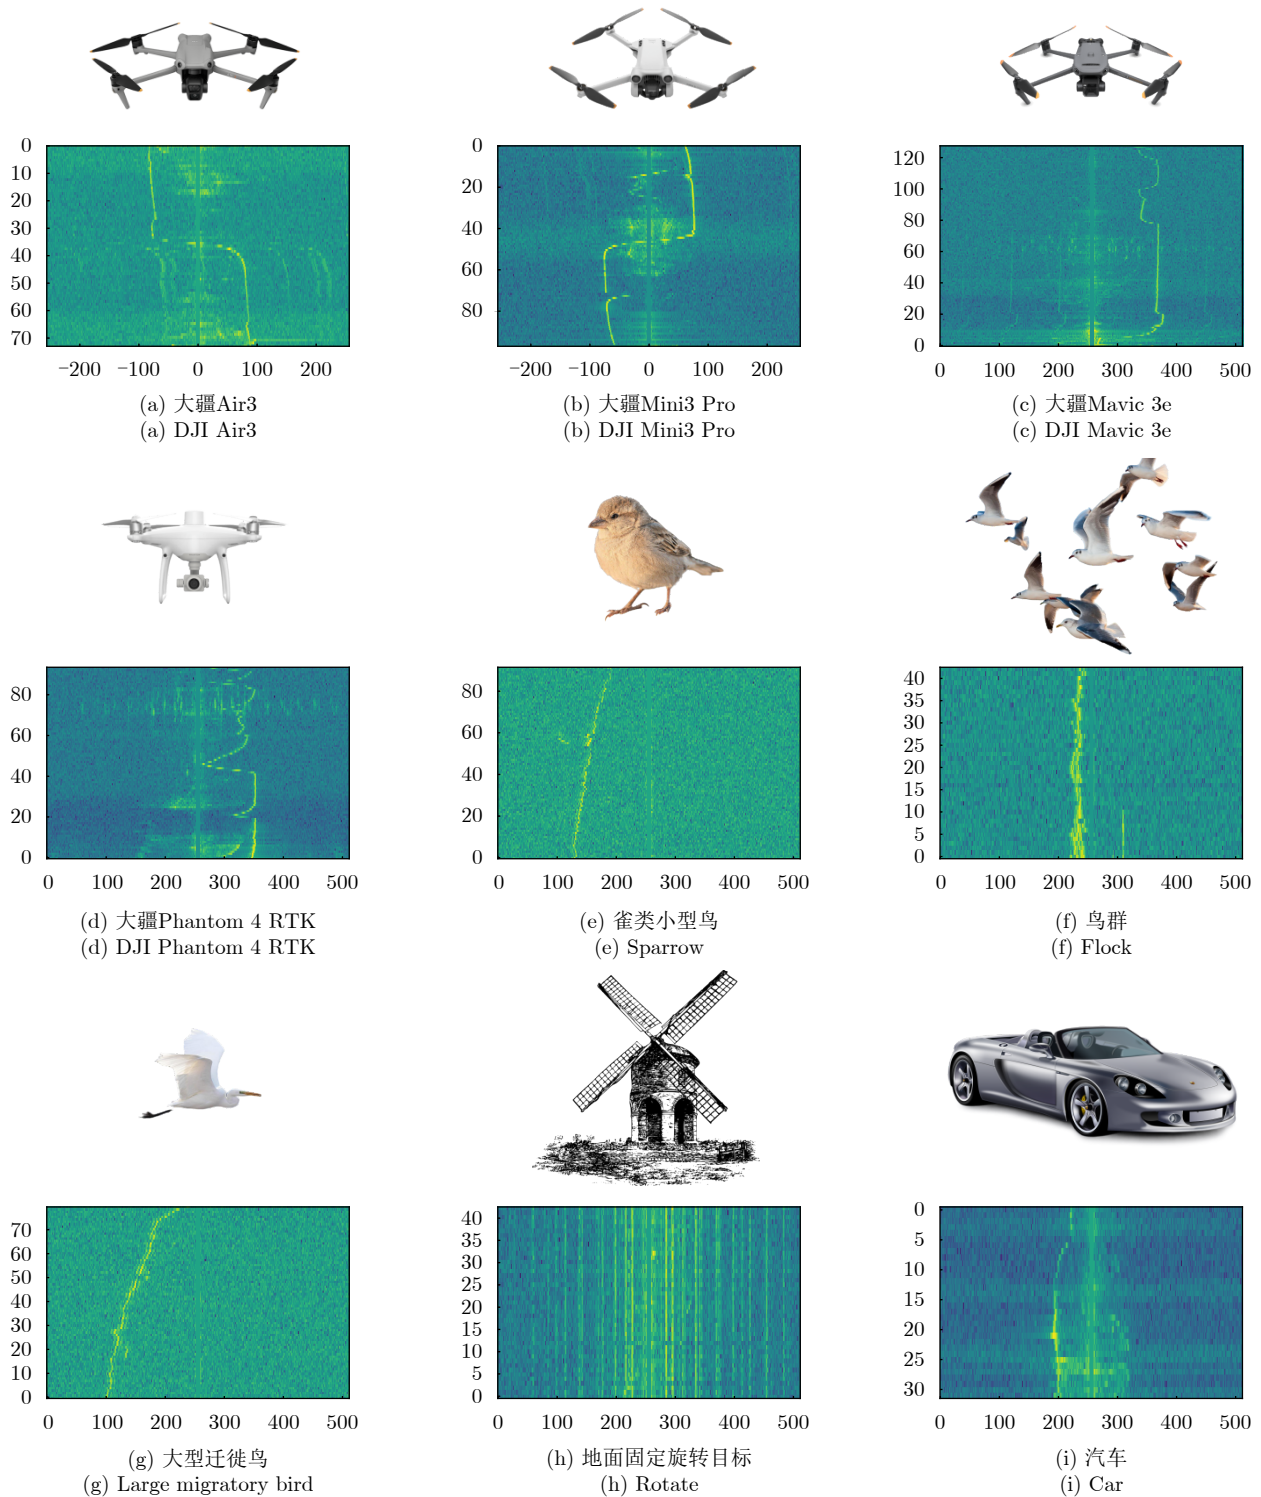


图3 不同目标的多普勒瀑布图

Fig. 3 Micro-Doppler Waterfall Plot of different targets

各类目标航迹数目分布如表2所示。

3.2 数据集分析

首先,团队对数据集的距离分布进行了统计分析。如图5(a)所示,数据集中所有样本的航迹距离分布直方图显示,样本距离覆盖范围为0.3 km~10 km,

均值为2.16 km,中位数为1.76 km。分布整体呈现右偏态特征,表明数据集中包含大量近距离样本的同时,也涵盖了相当比例的远距离目标数据,具有较好的多样性。如图5(b)所示,将所有865个样本按平均距离从小到大排序,并展示了各样本的距离波动范围(最小值到最大值区间)。统计结果表明:

(1) 约20%的样本平均距离超过3 km, 属于中远距离探测场景;

(2) 约10%的样本平均距离超过5 km, 代表典型的远距离低信噪比场景;

(3) 部分样本的距离变化范围较大, 反映了目标在航迹持续时段内的径向运动特性。

为了进一步展示数据集中目标的信号质量特性, 选取典型的无人机(UAV)和鸟类(Bird)样本, 对其信噪比(Signal-to-Noise Ratio, SNR)、杂波强度以及随时间(回波帧数)的变化进行了详细分析, 结果如图6所示。对于无人机和鸟类目标, 其信噪比(图6(b)和图6(f))均随着距离的增加(参考图6(d)和图6(h))呈现出下降趋势, 符合雷达探测一般规律。背景杂波强度整体保持稳定(图6(c)和图6(g)),

但在无人机目标约1.5 km处由于雷达系统进行了波形切换, 背景杂波强度出现了瞬时跳变。这些结果表明, 该数据集能够真实反映不同距离下的信噪比变化规律以及雷达系统工作特性。

为了更清晰地说明本文所构建数据集与现有公开数据集的区别, 表3给出了从雷达体制、参数配置、目标特性及数据形态等多个维度, LSS-HSR-L与现有的LSS-FMCWR-1.0 和LSS-PR-1.0等主流数据集的对比结果。

4 多特征融合识别方法

为了充分挖掘本数据集提供的航迹多普勒多模态特征信息, 并验证该数据集在多特征融合任务中的应用价值, 本文提出一种多模态自适应特征融合网络作为核心融合识别框架。该网络抛弃了传统先提取、后融合的静态架构, 采用一种深度交互的双分支层级架构, 在特征提取的多个层级上, 通过自适应门控机制实时调节多普勒视觉纹理与宏观运动学特征的贡献度, 从而解决远距离、低信噪比环境下单模态信号质量动态波动导致识别失效问题。

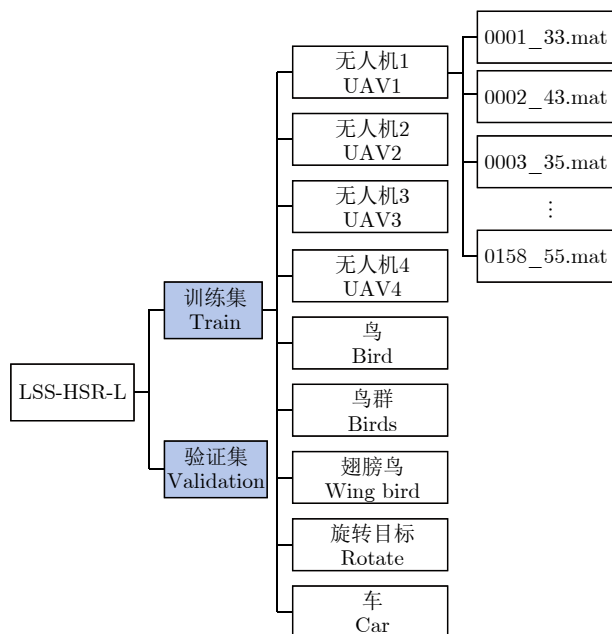


图 4 LSS-HSR-L数据集目录格式

Fig. 4 Directory structure of the LSS-HSR-L dataset

表 2 LSS-HSR-L数据集类别分布情况

Tab. 2 Class distribution of LSS-HSR-L dataset

类别名称	训练集航迹数	验证集航迹数
无人机1 (UAV1)	116	25
无人机2 (UAV2)	120	25
无人机3 (UAV3)	117	24
无人机4 (UAV4)	121	25
鸟(Bird)	158	30
鸟群(Birds)	114	24
翅膀鸟(Wing bird)	119	24
旋转目标(Rotate)	122	28
车(Car)	218	45

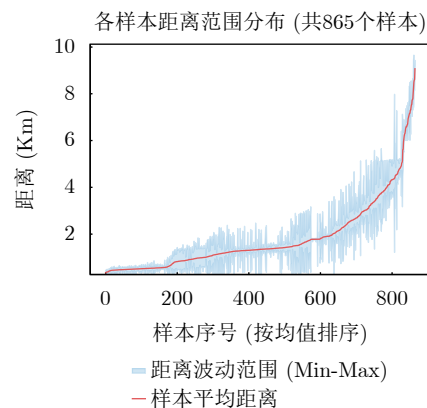



图 5 距离分布统计结果

Fig. 5 Statistical results of distance distribution

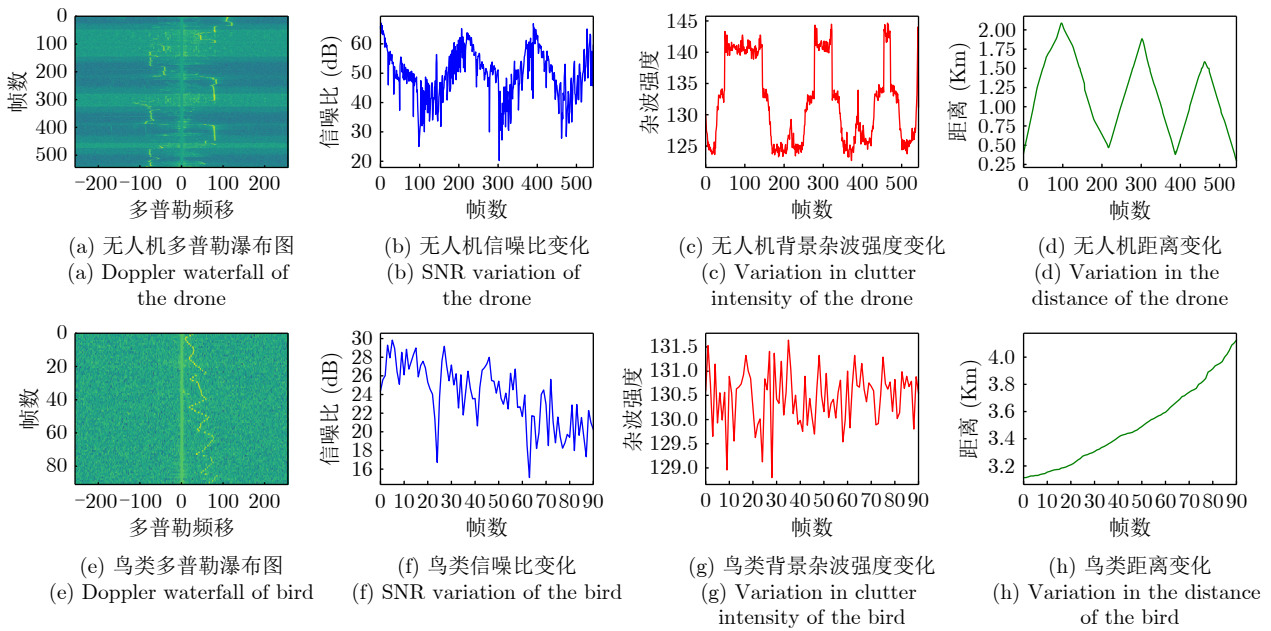


图6 典型样本的信噪比、杂波及运动参数分析

Fig. 6 Analysis of SNR, clutter and distance parameters of typical samples

表3 LSS-HSR-L数据集与典型数据集对比

Tab. 3 Comparison between LSS-HSR-L and typical datasets

对比项	LSS-FMCWR-1.0	LSS-PR-1.0	LSS-HSR-L
体制	多波段FMCW雷达	非合作被动雷达 (外辐射源DTMB)	全息凝视雷达
频段	Ku: 23.7 GHz; L: 1.4~1.5 GHz	470~806 MHz (DTMB)	L波段
带宽	Ku: 100/200/300/500 MHz; L: 100 MHz	7.56 MHz	4 MHz
更新周期/帧率	-	1 s	0.8 s
距离范围	5~30 m	~ km 级	0.3 ~ 10 km
目标类别	6类 (各类无人机)	4类 (无人机/直升机/快艇/客轮)	9类 (无人机/鸟类/车辆等)
数据模态	时频图	距离多普勒谱 + 航迹	多普勒瀑布图 + 航迹
模态对齐	-	是	是 (帧级严格对齐)
采样频率	500 kHz	-	5 MHz
标注方式	实验受控采集	结合ADS-B与人工校对	飞控日志、双盲人工交叉验证、光学图片抽检校验
核心优势	多波段融合特征	无源探测, 静默感知	远距离、凝视观测

4.1 网络整体架构

多模态自适应特征融合网络的整体拓扑结构如图7所示, 其核心设计遵循交互式阶梯融合的原则。该架构构建了并行的多普勒分支与航迹分支, 在4个级联的分层特征提取阶段, 通过交织部署的语义桥接与门控融合模块, 实现了异构数据流在多尺度空间与不同语义维度下的深度融合。

网络处理链路起始于异构双流编码阶段, 其中多普勒处理分支接收多普勒瀑布图, 通过由4个残差块构成的编码器, 实现从复杂的时频分布中解耦出旋翼转动、机体运动等诱发的精细微动指纹特

征。同时, 航迹处理分支同步处理多参数航迹序列, 通过相应的4个对应的时序编码块捕捉目标的宏观行为模式, 如速度变化趋势与机动性等宏观特征。为了实现微观纹理特征与宏观语义特征的渐进式耦合, 网络在4个连续层级上部署了交互单元。在每一层级中, 双分支独立输出模态特异性特征给语义桥接模块, 进而进行空间对齐并输出对齐特征, 自适应融合模块将原始的双分支特征与对齐特征进行动态加权融合, 生成该层级的融合表征。在整个架构的后端, 4个层级生成的融合特征接入特征金字塔网络。特征金字塔网络通过自顶向下的路

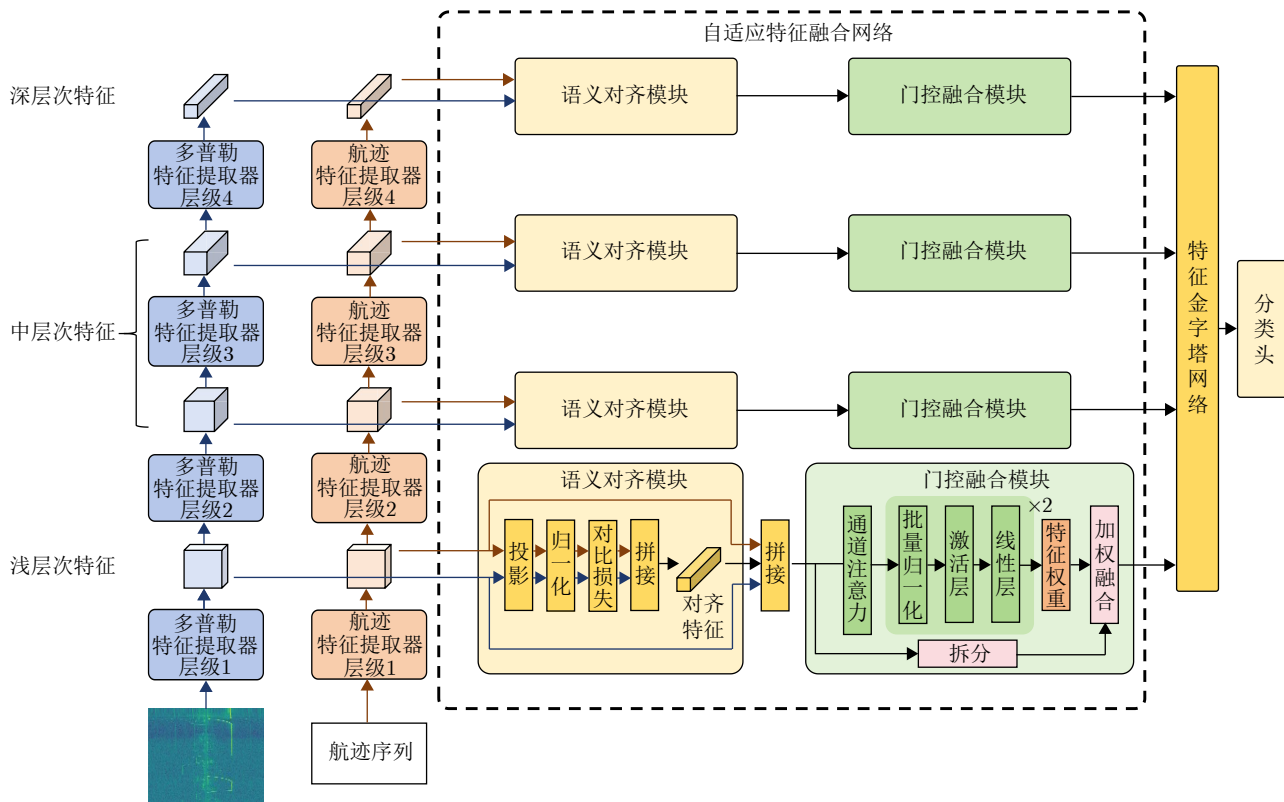


图 7 多模态自适应特征融合网络架构

Fig. 7 Architecture of the multi-modal adaptive feature fusion network

径, 通过 1×1 卷积调整特征通道数, 并通过侧向连接机制将深层的抽象语义特征与浅层的空间特征细节逐级融合。最终生成的统一特征向量交由分类器, 实现对目标类别判定。

4.2 语义桥接模块与跨模态特征对齐

针对瀑布图(图像域)与航迹序列(时序域)之间显著语义差异, 在各层级设置了语义桥接模块用于建立跨模态特征的关联基础。该模块通过“空间投影与对比学习监督”的逻辑链条, 实现从特征对齐到语义交融的特征转换。

模块利用投影头将双分支特征映射至共享嵌入空间。该投影头在全连接变换中引入残差连接与归一化, 并在输出端执行 L_2 归一化, 确保异构特征在映射过程中既能保持原始信息完整性, 又能获得稳定的特征表征维度。在训练阶段, 模块引入对称 InfoNCE 损失函数作为监督损失, 通过计算跨模态相似度矩阵使同一目标的特征在空间上相互靠近。经空间对齐后的双分支特征通过拼接实现深度融合, 生成兼具语义一致性与模态互补性的增强表征, 为后续自适应融合模块提供高度判别性的特征输入。

4.3 门控融合模块与动态权重调节

为了在实测环境下实现对信号质量动态变化的

稳健适配处理, 网络在每一层级设置了自适应融合模块作为多源信息融合的核心单元, 其详细架构如图7中的门控融合模块所示。该模块同时接收来自当前层级的原始多普勒特征、原始航迹特征以及由语义桥接对齐模块输出的对齐特征, 构建基于残差互补逻辑的多源特征输入体系。这种设计不仅保留了未经压缩的底层特征细节, 还引入了深层的对齐语义, 为自适应决策提供了多维度参照。

在模块内部, 三路输入特征送入基于通道注意力机制的加权环节, 结合门控多层感知器对各支路的置信度进行实时评估。该权重评估机制输出一组互补的自适应权重系数 (α, β, γ) , 分别作用于对应的多普勒、航迹及对齐特征支路。经执行加权求和运算后, 门控融合模块能够根据样本的实时特性动态调节各模态的贡献权重。例如, 当探测目标距离较远导致瀑布图信噪比下降时, 该模块将自动降低 α 并提高 β , 从而将决策重心向更稳健的航迹模态转移。这种基于数据驱动的动态融合机制, 让网络在复杂外场干扰下展现出优异的自适应性和识别鲁棒性。

5 实验验证与分析

5.1 数据集设置

首先, 在样本构建之前, 为保证模型评估的客

观性,在航迹层面将该数据集划分为训练集和验证集(如表2所示),从源头上避免了因数据同源(即同一条航迹的片段数据同时出现在训练集和验证集中)导致的评估结果虚高问题。其次,考虑到在真实的识别场景中,雷达数据是以数据流形式序贯传输至识别模块,若将整条航迹多普勒数据一次性送入识别网络,不仅计算开销巨大,也无法满足实时性要求。为了模拟这一实际应用需求,并保证模型能够对目标的动态过程实现连续稳定判别,采用滑窗法对多普勒瀑布图和航迹序列进行切分,构造最终的模型学习样本(如图8所示)。本文实验中,将完整的多普勒和航迹序列切分为一系列长度固定为10帧且部分重叠的子序列,每个子序列定义为一个独立的样本。其中无人机由于采集难度大,航迹较短,使用步长为1帧的滑窗生成样本;鸟类等其他航迹较长且数量较多的样本,步长设置为3帧或者5帧。通过此方法,最终为每个类别构建了5000个训练样本和1000个验证样本。

5.2 数据集基准识别实验

为有效验证构建数据集的合理性与有效性,本文首先设计了一系列基准实验。实验所采用的模型均基于成熟的开源库构建:其中,处理多普勒数据的模型源自timm库,而处理航迹数据的时序模型则源自tsai库。所有实验均基于Python 3.10和PyTorch 2.6.0深度学习框架实现。硬件平台配置为Intel Core i7-13700KF处理器、32 GB 内存以及NVIDIA GeForce RTX 4060 Ti GPU,并采用CUDA 12.6进行加速。在模型训练阶段,采用AdamW作

为优化器,其权重衰减系数(weight decay)设为0.01。初始学习率设置为 1×10^{-4} ,并采用StepLR学习率调度策略,其调整步长(step_size)在训练视觉模型时设为15轮,在训练时序模型时设为50轮,衰减因子(gamma)为0.5。批处理大小(batch size)为64。为确保不同模型充分收敛,训练轮次(epoch)依据输入数据的不同进行了调整:当模型仅使用多普勒数据时,即训练视觉模型时,训练30轮;当仅使用航迹数据时,即训练时序模型时,则训练100轮。模型具体的网络结构与超参数详见表4。

实验中,针对以多普勒瀑布图为输入的视觉模型包括经典的ResNet系列、高效的EfficientNetV2以及现代化的ConvNext等;针对以航迹数据为输入的时序模型则涵盖了InceptionTime,ROCKET及PatchTST等代表性算法。为客观评估模型在目标分类任务上的性能,本文主要选取了模型总体准确率(Accuracy, ACC)和每个类别的召回率(Recall)作为核心评价指标。不同算法的核心指标对比如表5^[25-52]所示。表中,RC-UAV1至RC-UAV4分别代表4种无人机,RC-Bird,RC-Birds,RC-WingBird分别代表3种鸟类(Bird, Birds, Wing Bird),RC-Rotate代表旋转翼(Rotate),RC-Car代表汽车(Car)的召回率。所有指标数值越高代表性越好,每一列的最优值已加粗显示。

从表5的实验结果来看,使用多普勒瀑布图的视觉模型(timm库)在总体准确率指标上普遍优于使用航迹数据的时序模型(tsai库)。其中,来自timm库的Res2Net模型取得了最佳的综合表现,ACC达到了89.8%。此外,csenet(89.4%)和denseNet

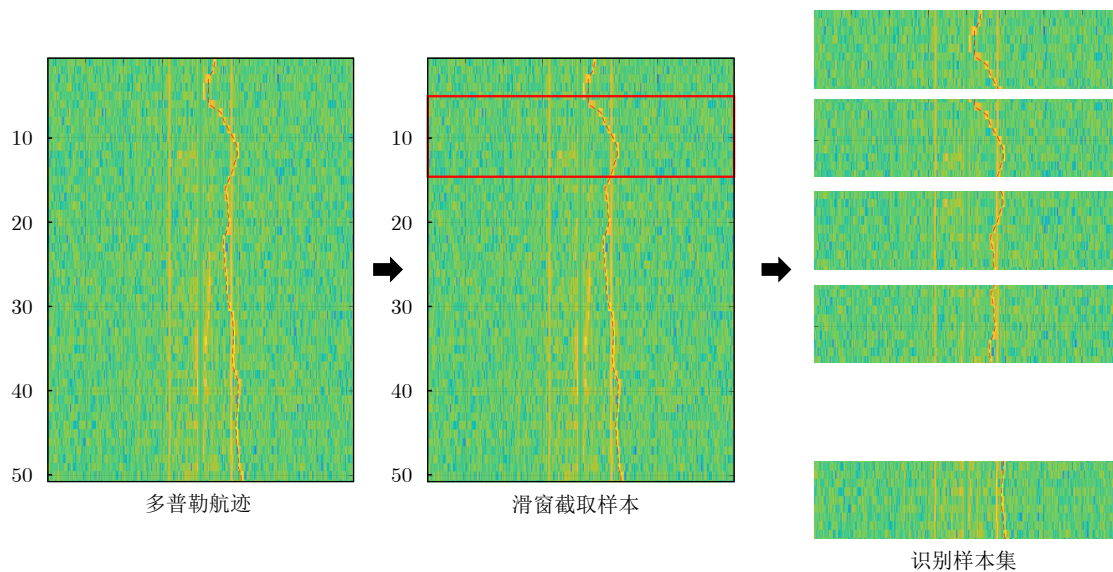


图8 从多普勒瀑布图到滑窗样本

Fig. 8 From Doppler waterfall plot to sliding window sample

表 4 数据集有效性验证实验超参数
Tab. 4 Hyperparameters for dataset validity verification experiments

参数	指标
优化器	AdamW
损失函数	Cross Entropy Loss
学习率调度器	StepLR
初始学习率	1×10^{-4}
批次大小	64
训练轮数	100或30

(89.2%)也取得了具有竞争力的结果。上述实验结果在一定程度上验证了该数据集的有效性。多个视觉基准模型能够普遍取得接近90%的准确率, 这表明数据集中不同类别的样本特征具有较好的可区分性, 为模型学习提供了有效特征模式。此外, 实验结果也表明视觉模型普遍优于时序模型, 说明经过预处理生成的多普勒瀑布图比原始航迹数据蕴含更丰富、更具判别性的特征信息。综上所述, 通过在多个基准模型上的综合测试与分析, 验证了本文所构建数据集的可靠性与有效性, 可作为分类识别算法验证基础。

表 5 各视觉模型与时序模型在LSS-HSR-L数据集的召回率及总体准确率 (%)
Tab. 5 Recall and ACC of each visual model and temporal model on the LSS-HSR-L dataset (%)

算法名称	RC-UAV1	RC-UAV2	RC-UAV3	RC-UAV4	RC-Bird	RC-Birds	RC-WingBird	RC-Rotate	RC-Car	ACC	
视觉模型 (Timm)	ConvNet ^[25]	69.6	76.2	64.1	65.4	13.8	57.1	30.5	96.0	59.5	59.1
	CSPNet ^[26]	86.2	84.6	86.1	85.4	97.4	88.4	83.4	99.1	91.9	89.2
	DenseNet ^[27]	86.6	87.3	88.3	78.7	96.1	93.3	79.8	98.3	96.2	89.4
	EfficientnetV1 ^[28]	63.2	74.8	68.8	75.7	86.1	67.7	49.3	90.0	70.6	71.8
	EfficientnetV2 ^[29]	75.7	86.7	83.4	82.5	96.8	76.8	64.8	99.3	74.5	82.3
	GhostNet ^[30]	79.2	86.3	80.5	85.5	96.6	81.5	62.5	99.0	83.3	83.8
	HRNet ^[31]	84.0	89.4	85.4	84.4	94.9	77.5	73.3	99.6	80.4	85.4
	PP-LCNet ^[32]	55.3	66.4	67.6	69.6	88.2	41.3	45.8	88.8	56.7	64.4
	MobileNetV3 ^[33]	78.6	80.7	81.2	74.6	94.1	80.5	56.3	98.2	74.6	79.9
	RegNet ^[34]	79.2	82.9	80.8	81.3	94.7	83.9	84.5	99.4	70.9	84.2
	Res2Net ^[35]	85.0	87.3	85.7	85.1	96.8	93.4	88.7	99.0	86.8	89.8
	Resnet18 ^[36]	79.1	79.2	80.2	84.2	97.7	80.4	90.4	98.4	88.4	86.4
	Resnet34 ^[36]	81.5	83.3	79.6	85.8	96.6	80.3	88.6	99.0	90.8	87.3
	Resnet50 ^[36]	79.3	86.0	82.9	86.1	95.2	86.8	80.4	99.2	89.7	87.3
	TinyNet ^[37]	73.1	80.5	79.6	80.4	95.8	70.8	46.9	96.2	71.2	77.2
	VGG ^[38]	88.3	87.6	80.0	87.3	84.1	48.1	37.8	97.9	84.6	77.3
	FCN ^[39]	76.3	85.4	79.3	63.0	79.5	37.9	31.8	98.6	94.5	71.8
	gMLP ^[40]	77.0	86.2	80.9	60.5	31.3	26.8	95.4	99.1	86.4	71.5
	GRU_FCN ^[41]	82.8	87.9	84.5	65.7	85.4	32.5	37.8	98.9	93.0	74.3
	InceptionTime ^[42]	80.5	87.4	84.7	79.9	76.4	32.5	42.7	99.3	95.2	75.4
LSTM-FCN ^[43]	81.4	87.1	83.9	69.7	72.8	38.6	42.7	98.9	94.3	74.4	
MiniRocket ^[44]	81.5	80.1	77.1	80.7	84.1	46.9	31.1	97.1	88.9	74.2	
OmniScale ^[45]	79.7	88.3	85.8	76.9	89.3	34.6	34.9	99.8	92.9	75.8	
时序模型 (tsai)	PatchTST ^[46]	16.9	47.1	50.8	29.0	47.8	27.0	60.6	83.9	96.9	51.1
	ResCNN ^[47]	85.6	87.7	80.4	72.8	89.8	34.1	41.4	99.5	92.3	76.0
	ResNet ^[39]	79.8	87.8	86.2	73.1	85.3	41.6	37.5	98.9	93.0	76.0
	Rocket ^[48]	69.2	29.0	48.5	58.9	38.5	19.9	63.6	93.3	84.4	56.1
	TSPerceiver ^[49]	62.7	73.4	63.7	66.1	70.2	20.6	36.0	98.5	94.6	65.1
	TSSequencer ^[50]	63.1	74.3	69.6	64.0	70.1	22.9	40.8	99.6	92.2	66.3
	XceptionTime ^[51]	86.1	90.6	84.1	79.8	86.8	46.1	44.8	99.0	95.0	79.1
	XCM ^[52]	82.2	84.6	64.7	39.4	75.5	23.6	46.6	99.8	91.0	67.5

注: 加粗数值表示所在列最优。

5.3 多特征融合识别实验

5.2节基准识别实验分别验证了基于多普勒瀑布图的视觉特征与基于航迹数据的时序特征在低空目标分类任务中的有效性。微多普勒谱图更擅长表征旋翼/扑翼等微观运动细节,而航迹中的速度、加速度及转弯等量测更适合描述目标的宏观飞行行为。当微动纹理因距离增大、信噪比下降或目标滑翔而减弱时,运动学特征可提供更稳定的补充,反之精细时频纹理又能弥补仅依赖航迹时对相似目标区分能力不足的问题^[15,16,18,53]。因此,为进一步挖掘两类信息的互补性,本节在统一的“多普勒瀑布图-航迹”一体化框架下设计多特征融合实验,以提升整体识别准确性与稳健性。

模型总体采用如图7所示的双流结构并行处理两路数据。其中视觉分支选用ResNet-34架构,该分支在4个层级上的输出通道数分别为64, 128, 256和512。航迹分支以长度为10的航迹滑窗序列作为输入,每一时刻包含径向速度、距离、方位角、高度和归一化信噪比5个量测维度,航迹分支编码器采用基于EfficientNet-B0轻量化改进的二维卷积网络,其4个层级的输出通道数分别为24, 48, 96和512。样本构造时航迹窗口长度固定为10。在跨模态交互过程中,本文在4个层级分别执行特征对齐与融合。对于前3个层级,由于两分支输出通道数不一致,先采用 1×1 投影层将航迹分支特征分别映射到与多普勒分支对应层一致的通道维度,即 $24 \rightarrow 64$, $48 \rightarrow 128$, $96 \rightarrow 256$;再执行全局平均池化,得到定长层级特征向量。第4层两分支输出通道数均为512,因此直接进行全局平均池化得到语义特征。各层级对齐后的特征送入语义桥接模块和自适应门控融合模块,生成4个层级的融合表征,最后经拼接后输入分类头得到9类目标的识别结果。

在融合策略方面,本文依次探讨浅层次、中层次与深层次特征融合3种静态机制,并统一采用“拼接(Concatenation)”作为融合算子。为独立评估各层级的融合效果,上述每种机制在完成跨模态

特征拼接后,均统一馈入一个轻量级分类头网络,以执行表6所示的分类任务。其中:

浅层次特征融合侧重于浅层表征的协同:在完成时间戳对齐与尺度归一化后,两分支输出的底层特征映射经 1×1 卷积投影至一致的通道维度,然后进行拼接与轻量化卷积整合,使纹理边缘与局部航迹动态在特征提取初期便建立对应关系。

中层次特征融合面向语义级表征:通过提取两分支的中层特征,先进行全局池化或适配性降维以统一特征长度,进而直接拼接以实现微动模式与运动学模式在语义空间中的对齐。如图7所示,网络提取了两种不同深度的中层次特征,同时为保证对比实验的最佳性能,表6中的中层次融合实验选取了两者中分类指标更高的“层级2”特征进行特征拼接。

深层次特征融合作用于最终层级特征输出:分别提取两分支第4层级特征提取模块的输出特征,按固定顺序拼接形成决策级特征向量。总体而言,通过在不同深度一致采用拼接操作,模型在结构上保持了高度的简洁性与可复现性,同时确保跨模态关联信息能够被显式且逐步地注入最终的分类判别中。

在此基础上,本文进一步引入多模态自适应特征融合网络。与上述3种静态融合策略不同,该网络引入了自适应门控机制,能够根据输入信号的质量动态调整模态权重,实现“图-迹”信息的智能互补。

为确保对比的客观性,本次融合实验的训练轮数、优化器、学习率等超参数设置均与5.2节中的基准实验保持一致。不同融合策略的量化分类识别结果汇总见表6。

实验结果表明,在传统的静态融合策略下,模型的识别性能随特征融合层级的加深呈现出显著的递增趋势。具体而言,深层次特征融合的性能最优,中层次特征融合次之,而浅层次特征融合的表现相对较弱。其中,表现最佳的深层次特征融合策略总体准确率达到了89.7%。相比之下,本文提出的多模态自适应特征融合网络取得了最优的综合性

表6 不同融合策略下各类目标的召回率与总体准确率对比

Tab. 6 Comparison of Recall and ACC for each target under different fusion strategies

算法名称	RC-UAV1	RC-UAV2	RC-UAV3	RC-UAV4	RC-Bird	RC-Birds	RC-WingBird	RC-Rotate	RC-Car	ACC
浅层次融合	77.7	86.6	72.9	73.1	93.6	68.5	89.5	97.7	96.4	84.0
中层次融合	91.7	86.5	80.4	76.8	92.8	71.5	88.4	99.7	96.1	87.1
深层次融合	93.9	86.3	84.7	86.8	91.0	75.2	93.1	99.7	96.8	89.7
多模态自适应特征融合网络	93.0	83.6	92.1	88.8	92.4	86.4	85.6	99.6	95.2	90.7

能, 总体准确率进一步提升至90.7%。对各类别识别效果的深入分析表明, 该网络在难分样本的细粒度辨识上展现出显著优势。这一结果表明, 通过层级化交互对齐, 网络能够更有效地捕捉微弱的多普勒差异, 从而提升了对高相似度无人机目标的区分能力。

此外, 该网络在复杂干扰场景下也展现出卓越的鲁棒性。例如, 在极易因回波杂乱而引起混淆的“鸟群”类别上, 多模态自适应特征融合网络的召回率高达86.4%, 较深层次特征融合(75.2%)实现了近11%的显著提升。这充分印证了自适应门控机制的有效性: 当多普勒瀑布图因鸟群的非相干运动出现特征模糊或信噪比下降时, 网络能够智能地抑制受损模态的贡献权重, 转而依赖更稳定的航迹运动学特征, 从而大幅降低了类别误报率。尽管深层次特征融合在UAV1等部分强特征类别上表现与之接近, 但整体而言, 多模态自适应特征融合网络在各类别上的表现更为均衡。

本文所使用的数据集包含9个类别, 可归纳为无人机、鸟类及其他3大类。为分析模型误分类的来源, 本文对混淆情况进行了统计, 结果如图9所示。对于所提多模态自适应特征融合网络, 验证集共发生833个误分类, 其中跨3大类(无人机、鸟类、地面目标)的误分类为182个, 占21.85%; 大类内部误分为651个, 占78.15%。这表明模型已经能够较稳定地区分不同大类目标, 而剩余错误主要集中在大类内部的细粒度识别任务上, 尤其体现在不同无人机型号以及不同鸟类子类之间的相互混淆。

此外, 为深入探究所提多模态自适应特征融合网络的内部决策机制, 验证其能否根据信号质量动态调整对各模态的依赖程度, 本节对模型推理过程中的门控权重变化展开深入分析。为评估系统的鲁棒性, 在实测数据的基础上加入了两种典型的仿真干扰, 即多普勒瀑布图中叠加加性高斯白噪声, 以及模拟航迹数据传输过程中出现的随机掉帧现象。

图10(a)给出了验证集中各分支权重(多普勒分支、航迹分支及特征对齐)随加性高斯白噪声信噪比变化的统计平均曲线。实验中忽略多普勒图的初始背景噪声, 横轴信噪比定义为总信号强度与注入白噪声强度的比值, 测试区间为-5 dB~20 dB。图中给出了不同噪声水平下的多普勒瀑布图与原始多普勒瀑布图的对比。当信噪比低于5 dB时, 强噪声导致多普勒瀑布图的微动特征模糊, 自适应门控模块感知到数据质量恶化后, 主动抑制多普勒分支的权重; 相反, 当信噪比高于5 dB时, 微动特征恢

复清晰可辨, 网络则自动提高多普勒分支权重, 并相应减弱对航迹信息的依赖。这一现象充分体现了模型在高质量数据下利用微动指纹进行精细化分类的优势。同时, 特征对齐权重在整个信噪比跨度内均保持较高水平, 证明了跨模态特征对齐机制在捕捉航迹与多普勒特征深层关联上的有效性与鲁棒性。

同时, 为评估模型在数据缺失工况下的鲁棒性, 图10(b)展示了航迹特征发生随机丢失时的权重代偿机制。实验中, 特征丢失的具体模拟方式为: 针对帧长为 N 、5个维度(共计 $5 \times N$ 个物理参数)的航迹窗矩阵, 随机将其中的元素置零, 以此模拟真实探测场景中因传感器失效造成的数据丢失现象。实验结果表明, 随着特征丢失数量的增加, 网络能够敏锐评估出航迹信息的可靠性下降, 使得航迹分支权重(β)随之降低。作为补偿, 多普勒分支权重(α)呈现自适应上升趋势, 而对齐特征权重(γ)则持续保持高位主导状态。这一多模态权重的动态重构过程, 有效弥补了数据残缺造成的信息损失, 保障了模型在不完整输入条件下的推断稳定性。

进一步, 针对异构双流输入中多普勒特征编码器的特征提取机制及自适应加权融合策略的有效性, 本节继续通过物理属性解析与消融实验进行了深度探讨。多普勒特征编码器并非盲目地进行数据拟合, 而是通过层级化的卷积操作, 实现了对多普勒瀑布图从底层物理属性到高层语义信息的逐级抽象, 这种提取过程与雷达多普勒效应具有明确的对应关系。

具体而言, 在浅层次特征提取阶段(层级1), 网络凭借较高的空间分辨率捕捉多普勒瀑布图中微小且瞬时的频率调制特征, 如旋翼高速旋转产生的周期性条纹细节, 这些浅层次细节特征构成了区分旋翼结构高度相似目标的物理基础。随着特征提取过程向深层次推进, 网络对信号的表征逐渐由局部细节转向全局语义规律。中层次网络(层级2与层级3)侧重于捕捉多普勒信号的宏观结构, 包括信号的能量分布包络、主体运动引起的中心频率偏移趋势以及散射中心间的相对运动关联, 在特征空间内起到了连接局部细节与高层属性的桥梁作用。在此基础上, 深层次网络(层级4)通过层级化下采样将特征演化为高度抽象的语义表征, 能够深刻反映目标运动的本质模式与能量时频分布规律, 主要用于在全局尺度上建立各类目标间的判别边界。

为了定量分析上述层级特征对识别性能的贡献并验证融合策略的优势, 本文采用“留一法”设计了消融实验, 通过依次剔除不同阶段的特征分支来观察系统性能的波动。如表7所示, 实验结果显示

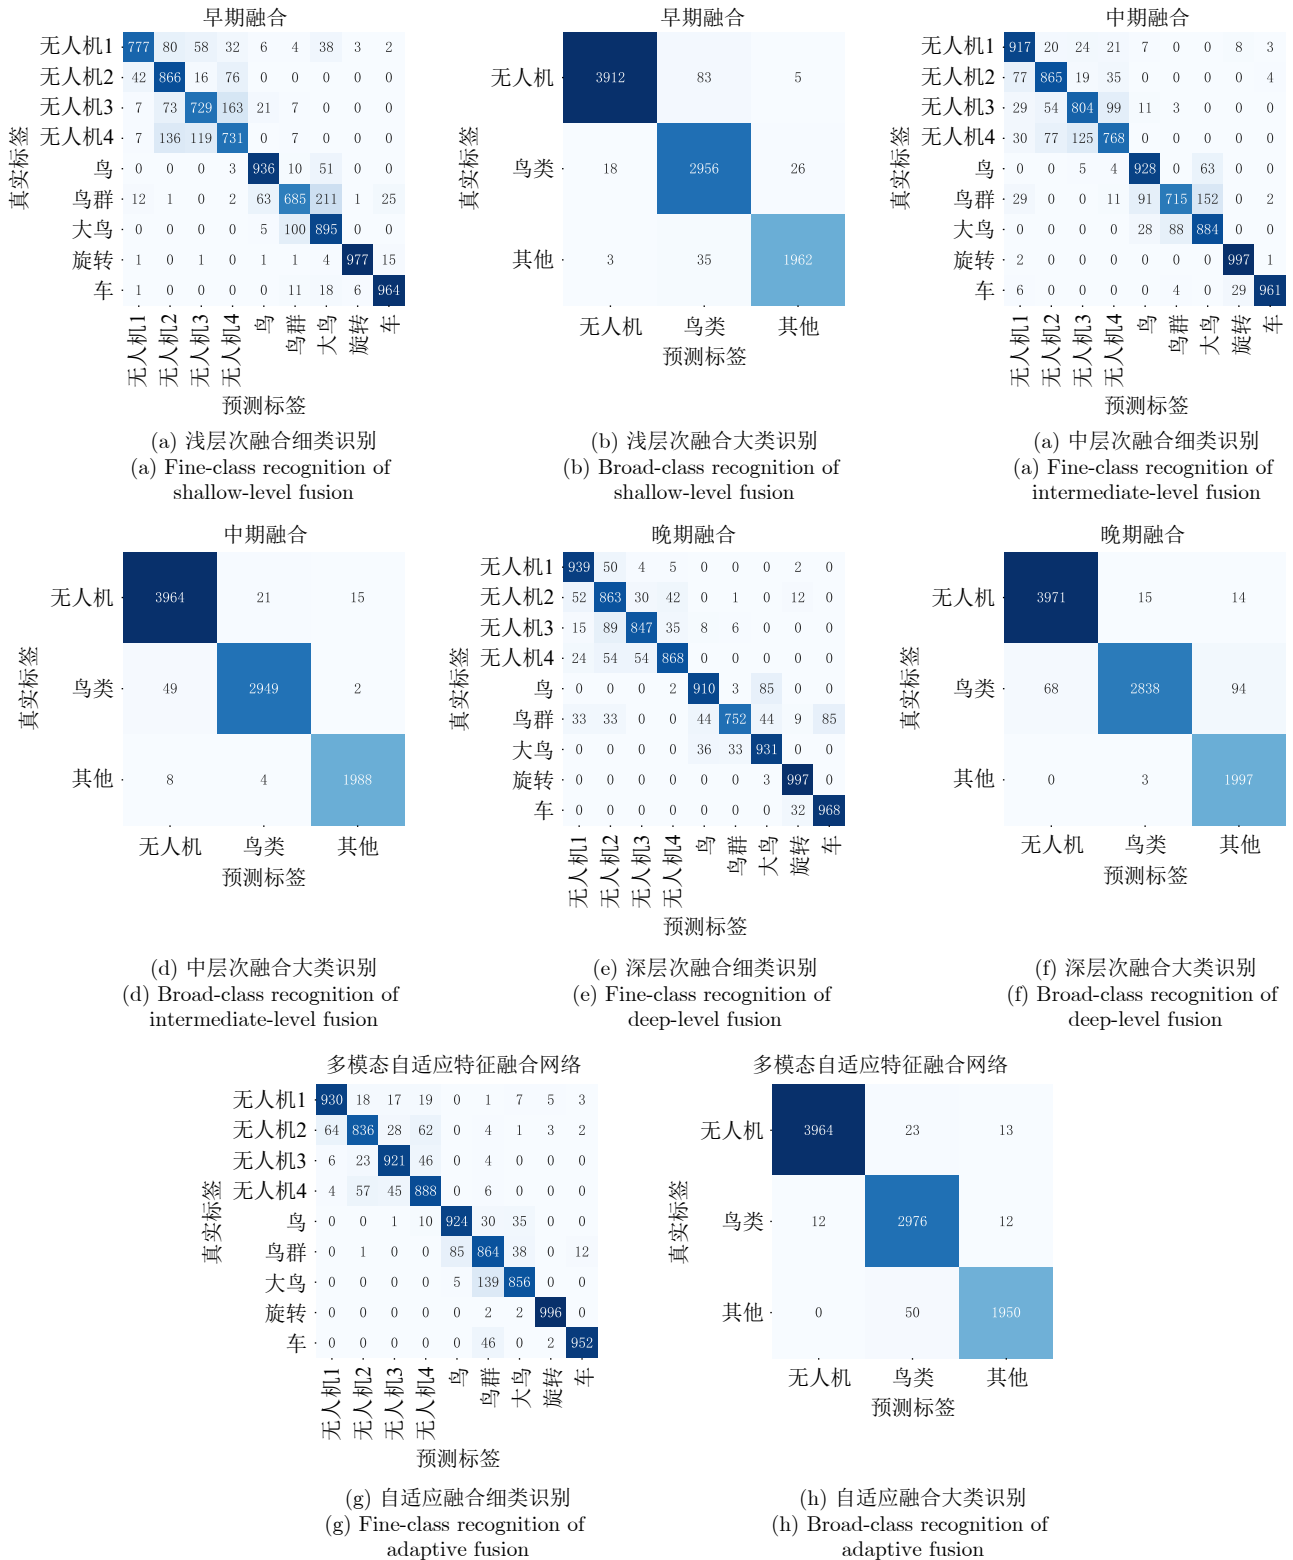


图9 不同融合策略下各类目标的识别性能对比

Fig. 9 Recognition performance comparison of different targets under various fusion strategies

任意层级的缺失均会导致准确率出现不同程度的下滑。其中，剔除层级1特征(实验5)后性能下降最为剧烈，达0.95%，反证了高分辨率微多普勒调制信息在细粒度识别中的不可替代性；而缺失层级4特

征(实验2)导致的0.88%性能损失则体现了深层语义信息在分类决策中的重要地位。此外，层级2(实验4)与层级3(实验3)的缺失分别导致了0.71%和0.29%的性能下降。

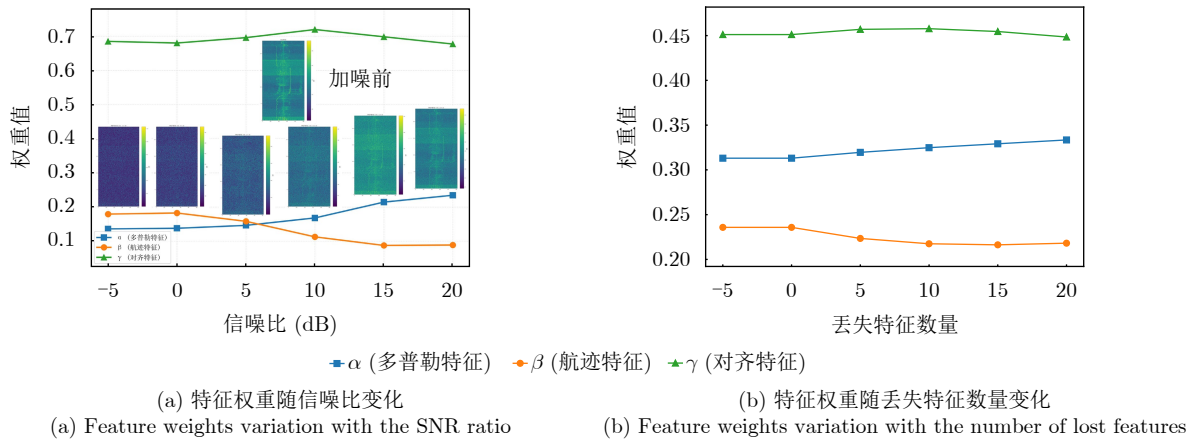


图 10 模型权重分配在不同干扰条件下的自适应变化
Fig. 10 Adaptive weight allocation under various interference conditions

表 7 不同特征层级组合对识别性能影响的消融实验

Tab. 7 Ablation experiments on the impact of different feature-level combinations on recognition performance

实验编号	层级1	层级2	层级3	层级4	总体准确率(%)	性能下降(%)
1	✓	✓	✓	✓	90.74	-
2	✓	✓	✓	-	89.86	0.88
3	✓	✓	-	✓	90.45	0.29
4	✓	-	✓	✓	90.03	0.71
5	-	✓	✓	✓	89.79	0.95

5.4 实际系统部署验证

为全面检验本文所提方法在真实环境下的识别性能与稳健性，本团队于2025年5月在中山大学深圳校区完成了识别模型的实地部署验证。雷达部署于校园楼顶，离地高度约20 m。试验在晴朗天气下开展，系统连续无人值守运行超过1小时，实时识别结果与显控可视化界面同步记录。图11呈现了系统运行期间的空域态势与实时识别效果可视化图，图中红色星标为雷达位置。从图11可见，雷达探测范围覆盖了建筑群、道路及起伏山体等复杂地貌，这些地物极易引发多径反射与信号遮挡，对远距离、低信噪比目标的稳定探测与精确分类构成了严峻挑战。

考虑到实地雷达应用场景，系统运行过程中不可避免地会观测到训练集定义之外的目标，而此类目标通常缺乏完备的先验标签。为避免将此类回波简单忽略而高估系统性能，本文将所有经观测可确认不属于无人机类与鸟类等重点关注目标但又无法进一步细分身份的目标统一归为“其他(Other)”类，用于表征开放环境中的未知目标与背景干扰。

本次实地部署模型的量化识别性能统计如表8所示。系统对无人机(实际测试无人机型号为大疆 Air3)目标表现出最为稳定的识别能力，在可验证




图 11 系统运行期间的空域态势与实时识别效果可视化图
Fig. 11 Visualization of real-time recognition effect of the holographic staring radar

表 8 全息凝视雷达实地部署识别情况(%)

Tab. 8 Recognition performance of HSR in real deployment(%)

类别名称	正确识别率	误报率
鸟类	92.6	9.1
无人机类	100	13.3
其他类	75	0

样本上取得了100%的正确率。结合图11的可视化结果，鸟类航迹(图中绿色轨迹)在校园中部及北侧

山体上空,具有分布广泛、活动密集且运动特性复杂等特点,并受地形遮挡、杂波起伏以及远距离低信噪比条件影响。在此条件下,系统对鸟类目标正确识别率达到92.6%,其9.1%的误报率主要来自于少数被系统识别输出为鸟类,但后续经光电系统复合或基于多普勒瀑布图与航迹特征联合判读后排除为鸟类目标的告警事件。对于“其他”类目标,系统在可核验样本上取得了75%的正确识别率,且未出现被系统判为“其他”但经复核后确认属于鸟类或无人机类的告警,因此其统计的误报率为0%。需要指出的是,该结果表示在已完成可靠复核的“其他”类告警中未发现反例,并不意味着真实环境中的全部未知目标均已被穷尽标注。总体而言,上述结果表明,尽管实地开放环境下仍存在由视场受限、远距离弱目标以及部分告警难以全量复核所带来的识别统计结果不确定性,所提出系统仍能够在连续无人值守运行条件下保持较好的目标区分能力与工程应用价值。

6 结语

本文围绕低空远距离目标识别算法验证难题,基于自主研发的L波段全息凝视雷达完成典型外场数据采集,发布了面向该体制雷达的公开实测数据集LSS-HSR-L。在远距离、低信噪比与复杂杂波条件下真实展现目标散射与时频特性,并同步提供与多普勒瀑布图严格时间对齐的航迹量测(距离、方位、高度、径向速度、归一化SNR),为“特征-航迹”一体化建模和识别奠定了基础。数据集覆盖9类目标(4类多旋翼UAV、3类鸟类、旋转体与车辆)。在基准实验中,以多普勒瀑布图为输入的视觉模型整体优于以航迹为输入的时序模型,验证了多普勒瀑布图携带的判别特征更强,而以“多普勒瀑布图+航迹”的多特征自适应融合进一步提升识别性能,体现出多普勒与运动学信息的互补性与协同增益。以上结果表明,LSS-HSR-L既能刻画远距离场景的真实统计,又能稳定支撑多类代表性模型与融合策略的性能对比,可有效支撑低空目标识别算法验证。

附录

LSS-HSR-L: 全息凝视雷达低空目标探测识别数据集依托《雷达学报》官方网站发布,现已上传至学报网站“数据”版块“低空目标探测数据集”,网址为:***** ,如附图1所示。

利益冲突 所有作者均声明不存在利益冲突

Conflict of Interests The authors declare that there is no

conflict of interests

参考文献

- [1] 王栋,赵洁,刘洋,等.多模态反无人机检测系统与技术[J].中国科学基金,2026,40(1):73-84. doi: [10.3724/BNSFC-2025-0024](https://doi.org/10.3724/BNSFC-2025-0024).
WANG Dong, ZHAO Jie, LIU Yang, et al. Multimodal anti-UAV detection system and technology[J]. *Bulletin of National Natural Science Foundation of China*, 2026, 40(1): 73-84. doi: [10.3724/BNSFC-2025-0024](https://doi.org/10.3724/BNSFC-2025-0024).
- [2] 汤洁,张明明,张东方,等.民航机场低空目标光电探测系统的研究和应用[J].激光与红外,2025,55(11):1776-1781. doi: [10.3969/j.issn.1001-5078.2025.11.018](https://doi.org/10.3969/j.issn.1001-5078.2025.11.018).
TANG Jie, ZHANG Mingming, ZHANG Dongfang, et al. Research and application of low altitude target photoelectric detection system in civil aviation airport[J]. *Laser & Infrared*, 2025, 55(11): 1776-1781. doi: [10.3969/j.issn.1001-5078.2025.11.018](https://doi.org/10.3969/j.issn.1001-5078.2025.11.018).
- [3] NILSSON C, LA SORTE F A, DOKTER A, et al. Bird strikes at commercial airports explained by citizen science and weather radar data[J]. *Journal of Applied Ecology*, 2021, 58(10): 2029-2039. doi: [10.1111/1365-2664.13971](https://doi.org/10.1111/1365-2664.13971).
- [4] 陈小龙,陈唯实,陈思伟,等.雷达低空目标探测与防范:进展与展望[J].中国科学基金,2026,40(1):48-64. doi: [10.3724/BNSFC-2025.07.25.0005](https://doi.org/10.3724/BNSFC-2025.07.25.0005).
CHEN Xiaolong, CHEN Weishi, CHEN Siwei, et al. Radar low altitude target detection and prevention: Progress and prospects[J]. *Bulletin of National Natural Science Foundation of China*, 2026, 40(1): 48-64. doi: [10.3724/BNSFC-2025.07.25.0005](https://doi.org/10.3724/BNSFC-2025.07.25.0005).
- [5] VARNOUSFADERANI E S and SHIHAB S A M. Bird strikes in aviation: A systematic review for informing future directions[J]. *Aerospace Science and Technology*, 2025, 163: 110303. doi: [10.1016/j.ast.2025.110303](https://doi.org/10.1016/j.ast.2025.110303).
- [6] 许道明,张宏伟.雷达低慢小目标检测技术综述[J].现代防御技术,2018,46(1):148-155. doi: [10.3969/j.issn.1009-086x.2018.01.024](https://doi.org/10.3969/j.issn.1009-086x.2018.01.024).
XU Daoming and ZHANG Hongwei. Overview of radar LSS target detection technology[J]. *Modern Defence Technology*, 2018, 46(1): 148-155. doi: [10.3969/j.issn.1009-086x.2018.01.024](https://doi.org/10.3969/j.issn.1009-086x.2018.01.024).
- [7] 屈旭涛,庄东晔,谢海斌.“低慢小”无人机探测方法[J].指挥控制与仿真,2020,42(2):128-135. doi: [10.3969/j.issn.1673-3819.2020.02.024](https://doi.org/10.3969/j.issn.1673-3819.2020.02.024).
QU Xutao, ZHUANG Dongye, and XIE Haibin. Detection methods for low-slow-small (LSS) UAV[J]. *Command Control & Simulation*, 2020, 42(2): 128-135. doi: [10.3969/j.issn.1673-3819.2020.02.024](https://doi.org/10.3969/j.issn.1673-3819.2020.02.024).
- [8] 陈小龙,陈唯实,饶云华,等.飞鸟与无人机目标雷达探测与识别技术进展与展望[J].雷达学报,2020,9(5):803-827. doi: [10.12000/JR20068](https://doi.org/10.12000/JR20068).

- CHEN Xiaolong, CHEN Weishi, RAO Yunhua, *et al.* Progress and prospects of radar target detection and recognition technology for flying birds and unmanned aerial vehicles[J]. *Journal of Radars*, 2020, 9(5): 803–827. doi: [10.12000/JR2006S](https://doi.org/10.12000/JR2006S).
- [9] 郭瑞, 张月, 田彪, 等. 全息凝视雷达系统技术与应用综述[J]. 雷达学报, 2023, 12(2): 389–411. doi: [10.12000/JR22153](https://doi.org/10.12000/JR22153).
- GUO Rui, ZHANG Yue, TIAN Biao, *et al.* Review of the technology, development and applications of holographic staring radar[J]. *Journal of Radars*, 2023, 12(2): 389–411. doi: [10.12000/JR22153](https://doi.org/10.12000/JR22153).
- [10] GRIFFITHS D, JAHANGIR M, KANNANTHARA J, *et al.* Fully digital, urban networked staring radar: Simulation and experimentation[J]. *IET Radar, Sonar & Navigation*, 2024, 18(5): 657–673. doi: [10.1049/rsn2.12499](https://doi.org/10.1049/rsn2.12499).
- [11] 周红平, 李睿, 李刘林, 等. 基于涡旋雷达的飞鸟与旋翼无人机微动参数提取研究[J]. 雷达学报(中英文), 待出版, 2026. DOI: [10.12000/JR25164](https://doi.org/10.12000/JR25164).
- ZHOU Hongping, LI Rui, LI Liulin, *et al.* Micromotions parameter extraction of birds and rotary-wing unmanned aerial vehicles based on vortex radar[J]. *Journal of Radars*, in press. 2026. DOI: [10.12000/JR25164](https://doi.org/10.12000/JR25164).
- [12] BENNETT C, JAHANGIR M, FIORANELLI F, *et al.* Use of symmetrical peak extraction in drone micro-Doppler classification for staring radar[C]. *2020 IEEE Radar Conference (RadarConf20)*, Florence, Italy, 2020: 1–6. DOI: [10.1109/RadarConf2043947.2020.9266702](https://doi.org/10.1109/RadarConf2043947.2020.9266702).
- [13] 张军, 田西兰. 基于雷达微多普勒特征的无人机集群识别[J]. 雷达科学与技术, 2025, 23(6): 692–699. doi: [10.3969/j.issn.1672-2337.2025.06.011](https://doi.org/10.3969/j.issn.1672-2337.2025.06.011).
- ZHANG Jun and TIAN Xilan. UAV swarm identification based on radar micro-doppler features[J]. *Radar Science and Technology*, 2025, 23(6): 692–699. doi: [10.3969/j.issn.1672-2337.2025.06.011](https://doi.org/10.3969/j.issn.1672-2337.2025.06.011).
- [14] KIM K, ÜNEY M, and MULGREW B. Coherent track-before-detect with micro-Doppler signature estimation in array radars[J]. *IET Radar, Sonar & Navigation*, 2020, 14(4): 572–585. doi: [10.1049/iet-rsn.2019.0319](https://doi.org/10.1049/iet-rsn.2019.0319).
- [15] LIU Jia, XU Qunyu, and CHEN Weishi. Classification of bird and drone targets based on motion characteristics and random forest model using surveillance radar data[J]. *IEEE Access*, 2021, 9: 160135–160144. doi: [10.1109/ACCESS.2021.3130231](https://doi.org/10.1109/ACCESS.2021.3130231).
- [16] DAI Ting, XU Shiyu, TIAN Biao, *et al.* Extraction of micro-doppler feature using LMD algorithm combined supplement feature for UAVs and birds classification[J]. *Remote Sensing*, 2022, 14(9): 2196. doi: [10.3390/rs14092196](https://doi.org/10.3390/rs14092196).
- [17] 唐世尧. 基于点航迹与MTD-距离图像融合的低空目标识别[J]. 科学技术创新, 2026(4): 70–74. doi: [10.3969/j.issn.2096-4390.2026.04.019](https://doi.org/10.3969/j.issn.2096-4390.2026.04.019).
- TANG Shiyao. Low-altitude target recognition based on fusion of point tracks and MTD-range images[J]. *Scientific and Technological Innovation*, 2026(4): 70–74. doi: [10.3969/j.issn.2096-4390.2026.04.019](https://doi.org/10.3969/j.issn.2096-4390.2026.04.019).
- [18] JIANG Wen, LIU Zhen, WANG Yanping, *et al.* Realizing small UAV targets recognition via multi-dimensional feature fusion of high-resolution radar[J]. *Remote Sensing*, 2024, 16(15): 2710. doi: [10.3390/rs16152710](https://doi.org/10.3390/rs16152710).
- [19] 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(中英文), 2024, 13(3): 539–553. doi: [10.12000/JR23142](https://doi.org/10.12000/JR23142).
- CHEN Xiaolong, YUAN Wang, DU Xiaolin, *et al.* Multiband FMCW radar LSS-target detection dataset (LSS-FMCWR-1.0) and high-resolution micromotion feature extraction method[J]. *Journal of Radars*, 2024, 13(3): 539–553. doi: [10.12000/JR23142](https://doi.org/10.12000/JR23142).
- [20] 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. doi: [10.12000/JR24145](https://doi.org/10.12000/JR24145).
- CHEN Xiaolong, RAO Guilin, GUAN Jian, *et al.* Passive radar low slow small detection dataset (LSS-PR-1.0) and multi-domain feature extraction and analysis methods[J]. *Journal of Radars*, 2025, 14(2): 249–268. doi: [10.12000/JR24145](https://doi.org/10.12000/JR24145).
- [21] 陈小龙, 袁旺, 杜晓林, 等. 多波段多角度FMCW雷达低慢小探测数据集(LSS-FMCWR-2.0)及特征融合分类方法[J]. 雷达学报(中英文), 2025, 14(5): 1276–1293. doi: [10.12000/JR25004](https://doi.org/10.12000/JR25004).
- CHEN Xiaolong, YUAN Wang, DU Xiaolin, *et al.* Multi-band multi-angle FMCW radar low-slow-small target detection dataset (LSS-FMCWR-2.0) and feature fusion classification methods[J]. *Journal of Radars*, 2025, 14(5): 1276–1293. doi: [10.12000/JR25004](https://doi.org/10.12000/JR25004).
- [22] 刘佳, 徐群玉, 陈唯实. 无人机雷达航迹运动特征提取及组合分类方法[J]. 系统工程与电子技术, 2023, 45(10): 3122–3131. doi: [10.12305/j.issn.1001-506X.2023.10.16](https://doi.org/10.12305/j.issn.1001-506X.2023.10.16).
- LIU Jia, XU Qunyu, and CHEN Weishi. Motion feature extraction and ensemble classification method based on radar tracks for drones[J]. *Systems Engineering and Electronics*, 2023, 45(10): 3122–3131. doi: [10.12305/j.issn.1001-506X.2023.10.16](https://doi.org/10.12305/j.issn.1001-506X.2023.10.16).
- [23] 陈唯实, 刘佳, 陈小龙, 等. 基于运动模型的低空非合作无人机目标识别[J]. 北京航空航天大学学报, 2019, 45(4): 687–694. doi: [10.13700/j.bh.1001-5965.2018.0447](https://doi.org/10.13700/j.bh.1001-5965.2018.0447).
- CHEN Weishi, LIU Jia, CHEN Xiaolong, *et al.* Non-cooperative UAV target recognition in low-altitude airspace based on motion model[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2019, 45(4): 687–694. doi: [10.13700/j.bh.1001-5965.2018.0447](https://doi.org/10.13700/j.bh.1001-5965.2018.0447).

- 13700/j.bh.1001-5965.2018.0447.
- [24] 刘旗, 郭瑞, 王佳佳, 等. 低仰角目标高精度波束空间DOA估计方法[J]. 雷达学报(中英文), 待出版. doi: [10.12000/JR25173](https://doi.org/10.12000/JR25173).
- LIU Qi, GUO Rui, WANG Jiajia, *et al.* A high-accuracy beamspace DOA estimation method for low-elevation angle targets[J/OL]. *Journal of Radars*, in press. doi: [10.12000/JR25173](https://doi.org/10.12000/JR25173).
- [25] LIU Zhuang, MAO Hanzi, WU Chaoyuan, *et al.* A ConvNet for the 2020s[C]. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, USA, 2022: 11966–11976. DOI: [10.1109/CVPR52688.2022.01167](https://doi.org/10.1109/CVPR52688.2022.01167).
- [26] WANG C Y, LIAO H Y M, WU Y H, *et al.* CSPNet: A new backbone that can enhance learning capability of CNN[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, USA, 2020: 1571–1580. DOI: [10.1109/CVPRW50498.2020.00203](https://doi.org/10.1109/CVPRW50498.2020.00203).
- [27] HUANG Gao, LIU Zhuang, VAN DER MAATEN L, *et al.* Densely connected convolutional networks[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, USA, 2017: 2261–2269. DOI: [10.1109/CVPR.2017.243](https://doi.org/10.1109/CVPR.2017.243).
- [28] TAN Mingxing and LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[C]. *The 36th International Conference on Machine Learning*, Long Beach, USA, 2019: 6105–6114.
- [29] TAN Mingxing and LE Q V. EfficientNetV2: Smaller models and faster training[C]. *The 38th International Conference on Machine Learning*, Online, 2021: 10096–10106.
- [30] HAN Kai, WANG Yunhe, TIAN Qi, *et al.* GhostNet: More features from cheap operations[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, USA, 2020: 1577–1586. DOI: [10.1109/CVPR42600.2020.00165](https://doi.org/10.1109/CVPR42600.2020.00165).
- [31] WANG Jingdong, SUN Ke, CHENG Tianheng, *et al.* Deep high-resolution representation learning for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(10): 3349–3364. doi: [10.1109/TPAMI.2020.2983686](https://doi.org/10.1109/TPAMI.2020.2983686).
- [32] CUI Cheng, GAO Tingquan, WEI Shengyu, *et al.* PP-LCNet: A lightweight CPU convolutional neural network[J]. arXiv preprint arXiv: 2109.15099, 2021. DOI: [10.48550/arXiv.2109.15099](https://doi.org/10.48550/arXiv.2109.15099).
- [33] HOWARD A, SANDLER M, CHEN Bo, *et al.* Searching for MobileNetV3[C]. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, Korea (South), 2019: 1314–1324. DOI: [10.1109/ICCV.2019.00140](https://doi.org/10.1109/ICCV.2019.00140).
- [34] RADOSAVOVIC I, KOSARAJU R P, GIRSHICK R, *et al.* Designing network design spaces[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, USA, 2020: 10425–10433. DOI: [10.1109/CVPR42600.2020.01044](https://doi.org/10.1109/CVPR42600.2020.01044).
- [35] GAO Shanghua, CHENG Mingming, ZHAO Kai, *et al.* Res2Net: A new multi-scale backbone architecture[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(2): 652–662. doi: [10.1109/TPAMI.2019.2938758](https://doi.org/10.1109/TPAMI.2019.2938758).
- [36] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, USA, 2016: 770–778. DOI: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [37] HAN Kai, WANG Yunhe, ZHANG Qiulin, *et al.* Model Rubik's cube: Twisting resolution, depth and width for TinyNets[C]. *The 34th International Conference on Neural Information Processing Systems*, Vancouver, Canada, 2020: 1623.
- [38] SIMONYAN K and ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. *The 3rd International Conference on Learning Representations*, San Diego, USA, 2015: 1–14.
- [39] WANG Zhiguang, YAN Weizhong, and OATES T. Time series classification from scratch with deep neural networks: A strong baseline[C]. *2017 International Joint Conference on Neural Networks (IJCNN)*, Anchorage, USA, 2017: 1578–1585. DOI: [10.1109/IJCNN.2017.7966039](https://doi.org/10.1109/IJCNN.2017.7966039).
- [40] LIU Hanxiao, DAI Zihang, SO D R, *et al.* Pay attention to MLPs[C]. *The 35th International Conference on Neural Information Processing Systems*, Online, 2021:9204–9215.
- [41] ELSAYED N, MAIDA A S, and BAYOUMI M. Deep gated recurrent and convolutional network hybrid model for univariate time series classification[J]. *International Journal of Advanced Computer Science and Applications*. 2019, 10(5): 654–664. DOI: [10.14569/IJACSA.2019.0100582](https://doi.org/10.14569/IJACSA.2019.0100582).
- [42] ISMAIL FAWAZ H, LUCAS B, FORESTIER G, *et al.* InceptionTime: Finding AlexNet for time series classification[J]. *Data Mining and Knowledge Discovery*, 2020, 34(6): 1936–1962. doi: [10.1007/s10618-020-00710-y](https://doi.org/10.1007/s10618-020-00710-y).
- [43] KARIM F, MAJUMDAR S, DARABI H, *et al.* LSTM fully convolutional networks for time series classification[J]. *IEEE Access*, 2018, 6: 1662–1669. doi: [10.1109/ACCESS.2017.2779939](https://doi.org/10.1109/ACCESS.2017.2779939).
- [44] TAN Changwei, DEMPSTER A, BERGMEIR C, *et al.* MultiRocket: Multiple pooling operators and transformations for fast and effective time series classification[J]. *Data Mining and Knowledge Discovery*, 2022, 36(5): 1623–1646. doi: [10.1007/s10618-022-00844-1](https://doi.org/10.1007/s10618-022-00844-1).
- [45] TANG Wensi, LONG Guodong, LIU Lu, *et al.* Omni-scale CNNs: A simple and effective kernel size configuration for

- time series classification[C]. *The Tenth International Conference on Learning Representations*, Online, 2022: 1–17.
- [46] NIE Yuqi, NGUYEN N H, SINTHONG P, *et al.* A time series is worth 64 words: Long-term forecasting with transformers[C]. *The Eleventh International Conference on Learning Representations*, Kigali, Rwanda, 2023: 1–24.
- [47] ZOU Xiaowu, WANG Zidong, LI Qi, *et al.* Integration of residual network and convolutional neural network along with various activation functions and global pooling for time series classification[J]. *Neurocomputing*, 2019, 367: 39–45. doi: [10.1016/j.neucom.2019.08.023](https://doi.org/10.1016/j.neucom.2019.08.023).
- [48] DEMPSTER A, PETITJEAN F, and WEBB G I. ROCKET: Exceptionally fast and accurate time series classification using random convolutional kernels[J]. *Data Mining and Knowledge Discovery*, 2020, 34(5): 1454–1495. doi: [10.1007/s10618-020-00701-z](https://doi.org/10.1007/s10618-020-00701-z).
- [49] JAEGLE A, BORGEAUD S, ALAYRAC J B, *et al.* Perceiver IO: A general architecture for structured inputs & outputs[C]. *The Tenth International Conference on Learning Representations*, Online, 2022: 1–29.
- [50] TATSUNAMI Y and TAKI M. Sequencer: Deep LSTM for image classification[C]. *The 36th International Conference on Neural Information Processing Systems*, New Orleans, USA, 2022: 2768.
- [51] RAHIMIAN E, ZABIHI S, ATASHZAR S F, *et al.* XceptionTime: A novel deep architecture based on depthwise separable convolutions for hand gesture classification[J]. arXiv preprint arXiv: 1911.03803, 2019. DOI: [10.48550/arXiv.1911.03803](https://doi.org/10.48550/arXiv.1911.03803).
- [52] FAUVEL K, LIN Tao, MASSON V, *et al.* XCM: An explainable convolutional neural network for multivariate time series classification[J]. *Mathematics*, 2021, 9(23): 3137. doi: [10.3390/math9233137](https://doi.org/10.3390/math9233137).
- [53] NARAYANAN R M, TSANG B, and BHARADWAJ R. Classification and discrimination of birds and small drones using radar micro-doppler spectrogram images[J]. *Signals*, 2023, 4(2): 337–358. doi: [10.3390/signals4020018](https://doi.org/10.3390/signals4020018).

作者简介

田 彪, 教授, 主要研究方向为雷达成像、波形设计、目标识别等。

陈俊彦, 博士生, 主要研究方向为开集识别、多模态特征融合与持续学习。

万延煜, 硕士生, 主要研究方向为多模态特征融合与开集识别。

黄仕林, 硕士生, 主要研究方向为雷达目标分类识别。

张 月, 教授, 主要研究方向为宽带数字化接收机技术, 新体制数字阵列雷达系统及信号处理技术等。

(责任编辑: 于青)