

基于PDW重构的智能机载雷达工作模式识别算法

李晨轩¹, 张劲东¹, 李一鸣², 李明杰¹

(1. 南京航空航天大学电子信息工程学院, 南京, 211106; 2. 中国人民解放军战略支援部队信息工程大学, 郑州, 450001)

摘要 针对脉冲丢失对机载雷达工作模式识别准确率影响较大的问题, 提出了一种基于脉冲描述字(PDW)重构的智能机载雷达工作模式识别算法。首先根据到达时间(TOA)的一阶差分序列提取到达时间差(DTOA)频繁项; 其次, 根据频繁项获得雷达真实的脉冲重复间隔(PRI)以及PRI变化规律; 再次, 计算不同PRI情况下的脉冲数完成PDW重构, 最后将重构后的PDW送入搭建好的时间卷积网络(TCN)识别机载雷达工作模式, 该方法能够挖掘PDW序列中的时间关联性, 可以更好地获取PDW序列的特征。通过仿真实验, 该方法在脉冲丢失率小于70%的情况下, 对于雷达工作模式的识别准确率能够达到95%以上。

关键词 脉冲丢失; 序列重构; 时间卷积网络; 雷达工作模式识别

DOI 10.3969/j.issn.2097-1915.2025.01.009

中图分类号 TN974 **文献标志码** A **文章编号** 2097-1915(2025)01-0067-09

An Intelligent Working Mode Recognition Algorithm for Airborne Radar Based on PDW Reconstruction

LI Chenxuan¹, ZHANG Jindong¹, LI Yiming², LI Mingjie²

(1. College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China; 2. PLA Strategic Support Force Information Engineering University, Zhengzhou 450001, China)

Abstract Aimed at the problem that pulse loss is a significant impact on mode recognition accuracy, an intelligent working mode recognition algorithm for airborne radar is proposed based on PDW reconstruction. Firstly, frequent DTOA items are extracted based on the first-order differential sequence of TOA. Secondly, the radar's true PRI and the PRI variation pattern are derived from these frequent items. Thirdly, the computed number of pulses under conditions of different PRI are to complete PDW reconstruction. Finally, the reconstructed PDW is inputted into a pre-built temporal convolution network (TCN) for recognizing the onboard radar working mode. Such a method can exploit the temporal correlation within the PDW sequence to further capture the features of the PDW sequence. The results show that the proposed method achieves a mode recognition accuracy of over 95% when the pulse loss rate is less than 70%.

Key words pulse missing; sequence reconstruction; temporal convolution network; radar working mode recognition

收稿日期: 2024-05-16

基金项目: 国家自然科学基金(62171220)

作者简介: 李晨轩(2000—), 男, 安徽池州人, 硕士生, 研究方向为电子对抗。E-mail: Krebs777@163.com

通信作者: 张劲东(1981—), 男, 江苏南通人, 博士, 研究方向为认知雷达与智能抗干扰、雷达信号处理。E-mail: zjdjs@126.com

引用格式: 李晨轩, 张劲东, 李一鸣, 等. 基于PDW重构的智能机载雷达工作模式识别算法[J]. 空军工程大学学报, 2025, 26(1): 67-75. LI Chenxuan, ZHANG Jindong, LI Yiming, et al. An Intelligent Working Mode Recognition Algorithm for Airborne Radar Based on PDW Reconstruction[J]. Journal of Air Force Engineering University, 2025, 26(1): 67-75.

机载雷达往往需要根据不同的任务需求选择不同的工作模式。工作模式的选择直接影响到雷达系统对目标的探测、识别和追踪能力。对敌方雷达工作模式的侦察判断,既能为后续开展雷达对抗提供信息支撑,也能为作战决策提供情报支援。因此,对机载雷达工作模式进行准确识别和分类成为了一项重要的研究任务^[1]。

机载雷达工作模式识别的研究旨在通过对雷达系统的信号特征进行分析与处理,实现对不同工作模式的自动识别。文献[2]提出一种基于图像化特征的雷达信号个体识别与工作模式识别方法。文献[3~6]使用 D-S 证据理论^[7]进行特征信息融合,有效提高雷达的工作模式识别的准确率。文献[8]提出一种基于复合赋权优劣解距离的识别方法。文献[9]基于扫描特征和信号样式应用关联分类 CBA 算法,即采用迭代方法挖掘特征中的频繁项集,并在此基础上启发式地构建分类器。

传统方法往往依赖于人工特征提取和分类器设计,但随着深度学习等技术的兴起,基于数据驱动的方法逐渐成为主流。这些方法通过大量样本数据,利用神经网络等模型自动学习雷达信号的特征表示,从而实现对工作模式的准确识别。文献[10~15]使用神经网络提取雷达信号的深层特征,实现对雷达工作模式的识别,验证了深度学习模型的强大特征提取能力与非理想性适应能力。然而这些方法存在脉冲丢失较大,对于工作模式识别的正确率不够稳定的问题。

针对上述问题,本文提出了一种基于脉冲描述字(pulse description word,PDW)序列重构的机载雷达工作模式识别方法。该方法利用脉冲重复间隔(pulse repetition interval,PRI)脉组捷变的规律进行脉冲序列的重构,有效减少脉冲丢失的影响,接着

将重构后的 PDW 送入时间卷积网络完成雷达工作模式端到端的识别。时间卷积网络采用卷积操作,可以进行高效的并行计算,充分利用现代硬件加速能力,适用于大规模数据处理。

1 机载火控雷达典型工作模式

机载火控雷达是战斗机执行多样化作战任务最重要的电子传感器。不同的工作环境和作战任务对雷达的功能要求也不一样,为了适应这种要求,雷达系统必须设计相应的工作模式满足对应的作战任务^[16-17]。典型的空-空模式包括速度搜索模式(velocity search,VS)、边测距边速度搜索模式(velocity search while ranging,VSR)、边搜索边测距模式(range while search,RWS)、搜索加跟踪模式(track and search,TAS)、单目标跟踪模式(single target track,STT)。表 1 为各模式的特点及参数范围。

由于机载多功能火控雷达工作模式较多且切换速度很快,用于雷达工作模式判定的特征应选取影响或反映雷达性能的重要参数。其中,脉冲宽度(pulse width,PW)影响雷达的距离分辨率;脉冲重复间隔,决定其最大不模糊距离、第一盲速,直接影响雷达的探测性能;频点 F_0 决定了工作频率;幅度 Amp 可以体现雷达天线方向图的调制信息。因此,本文选取 PRI、 F_0 、PW、Amp 构建雷达脉冲描述字,其数学表达式为:

$$\mathbf{PDW} = \begin{bmatrix} \text{PRI}_1 & \text{PRI}_2 & \cdots & \text{PRI}_n \\ \text{PW}_1 & \text{PW}_2 & \cdots & \text{PW}_n \\ F_{0_1} & F_{0_2} & \cdots & F_{0_n} \\ \text{Amp}_1 & \text{Amp}_2 & \cdots & \text{Amp}_n \end{bmatrix} \quad (1)$$

其中 n 表示某一工作模式下的脉冲数。

表 1 典型空-空模式特点及参数范围

Tab. 1 Typical characteristics and parameter ranges of air-to-air mode

工作模式	工作特点	PRI/ μs	PW/ μs	PRF 数量	单个 PRF 的脉冲数
VS	发现远距离高速度目标,提供目标速度和方位,采用高重复频率波形	6~10	1~2	1	1 000~2 048
VSR	与 VS 模式相似,并在 VS 的基础上使用高重复频率波形以提高平均功率的同时在脉间进行线性调频调制,从而实现远距离无模糊测距	6~10	1~2	1	1 000~2 048
RWS	搜索目标的同时进行测距不关联点迹,一般采用中重复频率波形	20~40	1~4	4~8	100~256
TAS	多目标跟踪的同时空域搜索,可以多目标打击,一般采样中重复频率波形	10~40	1~4	4~8	100~256
STT	单目标跟踪的同时空域搜索,可以精确制导	10~20	1~2	1	512~1 024

2 脉冲序列重构

由于环境干扰、装备性能、人为操作等各方面因素的影响,实际接收脉冲序列不可避免地会面临干扰脉冲、脉冲丢失、PRI 测量误差等问题。图 1(a)为无噪声没有丢失脉冲情况下的雷达脉冲图,图 1(b)为包含测量误差、脉冲丢失、伪脉冲情况下的雷达脉冲图,其中红色虚线为漏脉冲,斜线脉冲为测量误差情况下的脉冲,网格脉冲为伪脉冲。为了减少 3 种情况对工作模式识别的影响,需要对接收到的脉冲序列进行预处理,本文提出的脉冲序列重构方法可以很好地减少噪声对工作模式识别的影响。




图 1 雷达脉冲示意图

Fig. 1 Schematic diagram of radar pulse

2.1 提取 DTOA 频繁项

为了消除伪脉冲的影响,首先提取脉冲序列中频繁出现的到达时间差分(differential time of arrival, DTOA)值。设收到的脉冲序列的到达时间(time of arrival, TOA)为 $\{t_n\}$, $n=1,2,\dots,N$,根据收到的 TOA 构建一阶差分矩阵:

$$t_{\text{dtoa}} = [\Delta t_1, \Delta t_2, \dots, \Delta t_n] \quad (2)$$

$$\Delta t_n = t_{n+1} - t_n, n=1,2,\dots,N-1 \quad (3)$$

接着计算 DTOA 的最大值 Δt_{max} 以及最小值 Δt_{min} ,将最大值 $\lceil \Delta t_{\text{max}} \rceil$ 以及最小值 $\lfloor \Delta t_{\text{min}} \rfloor$ 设置为检索频繁 DTOA 的检索范围,并将 $\lfloor \Delta t_{\text{min}} \rfloor$ 到 $\lceil \Delta t_{\text{max}} \rceil$ 的时间范围按照 ΔT 进行离散化(其中 $\lfloor \cdot \rfloor$ 为向下取整, $\lceil \cdot \rceil$ 为向上取整, ΔT 的取值一般根据数据误差以及 PRI 的参数范围设置,本文设置为 $2 \mu\text{s}$),在时间轴上划分出 K 个区间,将每个区间的中心值记为 T_k , $k=1,2,\dots,K$ 。最后再定义一个 $2 \times K$ 的矩阵 C ,矩阵的第 1 行为每个区间的中心值 T_k ,第 2 行为每个区间统计的 DTOA 数量。矩阵 C 如式(4)所示,其中 m_k 为 t_{dtoa} 中 DTOA 在区间 $\left[T_k - \frac{\Delta T}{2}, T_k + \frac{\Delta T}{2}\right)$ 的脉冲数量。

$$C = \begin{bmatrix} T_1 & T_2 & \dots & T_k \\ m_1 & m_2 & \dots & m_k \end{bmatrix} \quad (4)$$

为了消除干扰脉冲的影响,避免在 PDW 重构过程中对干扰脉冲进行提取,首先提取脉冲序列中频繁出现的 DTOA,即将矩阵 C 中数量大于所设阈值 M_0 的 DTOA 提取出来(M_0 的值根据干扰脉冲的数量来设置,本文 M_0 设置为 20),并将提取出 DTOA 的值按从大到小的顺序构建频繁项 DTOA 集合。

$$\{\text{DTOA}_1, \text{DTOA}_2, \dots, \text{DTOA}_i\} \quad (5)$$

式中: i 表示侦收脉冲序列中出现数量超过预设阈值 M_0 的频繁项的数量。由于每个真实 PRI 在一个适当长度的侦收脉冲序列中会反复出现,因此总是包含在式(5)中的频繁项集中。干扰脉冲产生的伪 PRI 由于其随机值被排除在频繁项集中,从而在频繁提取过程中平滑了干扰脉冲的影响。然而,如图 1 所示,由脉冲丢失导致的非相邻脉冲(如 PRI1 + PRI1)引起的 DTOA 仍然保留在频繁项集中。因此,基于频率集的 PDW 重构的难度主要有两方面:一是消除缺失脉冲带来的干扰;二是计算 PRI 的周期顺序和当前 PRI 的脉冲数量。

2.2 PRI 周期规律提取

在式(5)给出的频繁项集中,根据 DTOA_i 出现频率 m_i 来判断其是否构成 PRI 模式是不正确的,这是因为非相邻脉冲区间 DTOA 的出现频率不一定低于其 PRI 分量,如 PRI1 + PRI1 出现的频率可能大于 PRI1 和 PRI2 的出现频率。

由于机载火控雷达的空-空模式 PRI 一般采用组变形式出现,如图 1 所示在经过第一步频繁项提取后频繁项 DTOA 集合中可能包含大量例如 PRI1 + PRI1、PRI1 + PRI1 + PRI1 等因为缺失脉冲导致的频繁项,基于这种情况,在提取 PRI 周期规律过程中,根据 DTOA 与其他 DTOA 的余数作为 PRI 的选择准则。

为了提取出 DTOA 频繁项中的由于缺失脉冲导致的频繁项,首先依次计算集合后面频繁项 DTOA_m 与当前频繁项 DTOA_n 的余数, $\beta_{n,m}$ 表示第 n 个频繁项与第 m 个频繁项的余数。

$$\beta_{n,m} = \text{mod}(\text{DTOA}_n, \text{DTOA}_m) \quad (6)$$

式中: $\text{mod}(\cdot, \cdot)$ 表示求余运算; DTOA_n 、 DTOA_m 分别表示第 n 个和第 m 个频繁项。

接着对 $\beta_{n,m}$ 的值进行判定,如果 $\beta_{n,m}$ 大于阈值 $\text{DTOA}_m - \epsilon$,小于阈值 ϵ ,则认为 DTOA_n 是因为脉冲丢失导致的频繁项,不是正确的 PRI。即若存在集合中的 DTOA_n 与 DTOA_m 满足式(7)则将 DTOA_n 剔除,因此获得真实的 PRI 集合 PRI_{true} 。例如 DTOA_1 与 DTOA_4 的余数小于 ϵ ,即存在

1)TCN 采用因果卷积,在因果卷积中,卷积核只能看到当前时间步之前的信息,而不能看到之后的信息。如图 4(a)所示,除了常规的因果卷积外,

TCN 还引入了扩展因果卷积,以更好地处理序列数据中的长期依赖关系。假设输入序列为 $x(t)$,输出序列为 $y(t)$,扩展因果卷积的计算式如下:

$$y(t) = \sum_{k=0}^K w(k)x(t-dk) \quad (12)$$

式中: d 是扩展因果卷积的因果率参数,控制卷积核能够看到的历史信息范围; K 是卷积核的长度; $w(k)$ 是卷积核的权重。

2)TCN 网络使用残差连接来缓解梯度消失问题,并帮助网络更好地捕获长期依赖性。TCN 残差块将因果卷积及残差连接方式相结合。如图 4(b)所示,这种结构使得 TCN 可以在较少的网络层数量下获得较大的感受野,更利于处理具有长期历史依赖的时序数据。因此,TCN 在处理长时间序列数据时具有明显的优势。





图 4 TCN 网络架构

Fig. 4 TCN network architecture

本文基于 TCN 的网络结构进行改进,设计了适合本文数据的 TCN 网络,图 5 为改进后 TCN 结构图。相比传统的 TCN 网络,本文主要做出了以下改进:




图 5 改进后 TCN 网络结构

Fig. 5 Improved TCN network structure

1)采用全局平均池化。传统 TCN 网络一般使用全连接层将输入的高维特征表示映射到输出的特征空间中,通过学习特征之间的线性组合,从而提取输入数据的更高层次的特征表示。本文将使用全局平均池化层代替全连接层提取全局信息。全局平均池化层的作用是将整个特征图的信息汇总成一个固定长度的向量,然后直接将这个向量作为模型的最终输出。经过实际测试,全局平均池化层减少模型的参数数量,加速模型的训练和推理速度并且减少过拟合的风险。

2)统一了输入尺寸和减少了残差块的数量。因为每个模式的脉冲数不一样,本文在重构 PDW 的同时会将 PDW 的输入长度按重构的变化规律进行填充,将每个 PDW 填充为 2048×4 的矩阵;本文模型使用 4 个残差块来提取数据特征,虽然残差模块越多,提取到的特征就越全局化,但经过实际测试,4 个残差模块就可以达到很好的训练效果。并且减少残差块的数量可以降低模型的复杂度,降低训练成本和计算量。表 2 展示了改进后的 TCN 网络参数量。

表 2 TCN 模型结构

Tab. 2 TCN model architecture

Layers	Params
Conv2D	$(3 \times 3 + 1) \times 32 = 320$
Residual Block	$(3 \times 3 \times 32 + 1) \times 32 = 9\ 248$
Residual Block	$(3 \times 3 \times 32 + 1) \times 32 = 9\ 248$
Residual Block	$(3 \times 3 \times 32 + 1) \times 32 = 9\ 248$
Residual Block	$(3 \times 3 \times 32 + 1) \times 32 = 9\ 248$
Global Average Pooling	0
Total Params	74 304

4 仿真分析

本部分主要通过仿真实验验证和分析基于 PDW 重构的智能机载雷达工作模式识别算法的有效性。为了模拟仿真实际环境,设置干扰脉冲占比 5%,脉冲丢失率为 0%~70%,直方图统计的 PRI 离散化间隔为 2 μs ,PDW 测量的相对误差为 2.5%,数据模拟用 MATLAB 完成,网络训练用 python 完成,数据产生和网络参数设置如下。

机载雷达空-空模式各模式按照表 3 所示参数进行设置。

表 3 各模式参数

Tab. 3 Parameters for each mode

工作模式	PRI/ μs	PW/ μs	F0/MHz	PRF 数量	单个 PRI 脉冲数量
VS	6~10	1~2	5 000~8 000	1	1 000~2 048
VSR	6~10	1~2	5 000~8 000	1	1 000~2 048
RWS	20~40	1~4	5 000~8 000	4~8	100~256
TAS	10~40	1~4	5 000~8 000	4~8	100~512
STT	10~20	1~2	5 000~8 000	1	512~1 024

上述各个模式模拟 PDW,在脉冲丢失率分别为 0%、10%、20%、30%、40%、50%、60%、70%的情况下各产生样本 2 000 个,共计 16 000 个,所有工作模式

的样本总数为 80 000 个。其中训练集、测试集、验证集按照 6:2:2 进行划分。输入网络的 PDW 大小为 $2\,048 \times 4$,网络输入 batch 大小为 256,每个卷积层的滤波器数为 32。模型经过 300 次训练,使用 Adam 优化器,初始学习率为 0.001。

4.1 PDW 重构结果

以 VS 模式、TAS 模式和 RWS 模式的其中 1 个情况为例,图 6 展示在脉冲丢失率为 50% 情况下进行重构前后 PRI 序列图。从图 6(a)中可以看出原始 PRI 序列因为丢失脉冲的影响,PRI 序列的部分已经特征丢失或者变形。这使得识别算法难以准确地提取出目标的特征,从而影响识别的准确性,并且脉冲丢失导致样式的混淆,使得原本不同的样式在识别时变得相似。从图 6(b)可以看出,采用上文提出的方法进行重构,在适当的脉冲数、缺失脉冲率和干扰脉冲比条件下,该方法可以稳定地从噪声污染的雷达脉冲序列中重建 PRI 图,重构后的序列恢复了 PRI 序列原有的特征,使得神经元能够更快地学习 PDW 的变化规律,以便在识别时更容易区分不同的模式。本文的重构算法依赖于 M_0 、 ϵ 数值的选择,设置失误会重构成虚假的 PRI 或者缺失真实的 PRI。但本文的重构算法计算复杂度较低,在不同的模式和脉冲缺失情况下运行时间均小于 2 ms。




图 6 重构前后 PRI 序列

Fig. 6 PRI sequence before and after reconstruction

4.2 TCN 网络与 CNN 网络对比

假设脉冲序列中存在的干扰脉冲数占比为

5%,脉冲丢失率为 50%。

图 7 为 CNN 网络+PDW 重构和 TCN 网络+

脉冲重构的训练结果图,从图 7 可以看出 TCN 网络验证集的正确率在更少的迭代次数后就完成了收敛,而 CNN 网络需要更多的迭代次数才可以完成收敛;并且 TCN 网络的验证集的正确率最终达到了 99.5%,而 CNN 网络的验证集正确率最终只达到了 79.9%。这说明相比于传统的卷积神经网络(CNN),它们通常依赖于固定长度的滑动窗口来处理输入数据,这种方法在捕捉时间序列中的长期依赖性方面存在局限。相反,时间卷积网络(TCN)能够更有效地处理序列数据中的长期时间相关性。这种能力使得 TCN 在雷达工作模式的识别任务中,展现出比 CNN 更为卓越的性能。并且改进后的 TCN 网络模型与权重占用的权重占用内存更小,调用训练保存下来的模型对未知类型的工作模式进行测试,本文算法只需要 17 ms 左右。






图 7 验证集准确率曲线

Fig. 7 Validation set accuracy curve

图 8 显示了工作模式的识别结果。从图 8(a) 可以看出,相比 TCN 网络,在没有干扰脉冲和伪脉冲的干扰下,CNN 网络依然难以区分 RWS 模式和 TAS 模式,其原因为 RWS 模式和 TAS 模式的参数混叠严重,CNN 网络难以捕捉较长的时间相关性,从而无法区分 RWS 模式和 TAS 模式。从图 8(b) 可以看出,原始脉冲序列虽然受到了伪脉冲,脉冲丢失等噪声干扰,但经过重构后仍然能实现工作模式的高精度识别,相比 CNN 网络,TCN 网络的 TAS 模式和 RWS 模式的识别准确率均在 99% 左右。因此,本文所提的方法对于机载雷达模式识别具有良好的优越性。



(a) CNN 网络



(b) TCN 网络

图 8 识别结果

Fig. 8 Recognition results

4.3 不同脉冲丢失率对比

图 9 展示了本文方法(R-TCN)、TCN 方法^[18]和 CNN 方法^[19]在不同脉冲丢失率下的识别准确率。可以看出,在脉冲丢失率小于 70% 的情况下,本文方法对雷达工作模式的识别准确率均高于 95%。然而,直接将未经处理的数据输入 TCN 网络和 CNN 网络时,随着脉冲丢失率的增加,雷达工作模式的识别准确率均出现下降。当脉冲丢失率达到 70% 时,CNN 网络和 TCN 网络的识别准确率均低于 80%。由于受到干扰脉冲和脉冲丢失的影响,PDW 的部分特征已经发生变形。这使得神经网络难以找到不同模式 PDW 的变化规律,从而影响了识别的准确性。




图 9 工作模式识别准确率与脉冲丢失率关系

Fig. 9 The relationship between work mode recognition accuracy and pulse loss rate

图 10 展示了 3 种方法在脉冲丢失率分别为 40% 和 70% 时的识别结果。可以看出,在这 2 种情况下,CNN 网络都无法区分 RWS 模式和 TAS 模式,这表明脉冲丢失对其影响不大。随着脉冲丢失率的增加,TCN 网络对除了 VSR 模式之外的各个模式的识别准确率都有所下降。过多的脉冲丢失导致 RWS 和 TAS 模式、VS 和 STT 模式之间的区分变得困难。然而,本文提出的方法对于每种模式的识别准确率受脉冲丢失的影响较小。

综上所述,本文提出的算法能够在脉冲丢失的

环境下更好地识别雷达的工作模式。这是因为脉冲序列经过重构后能够有效抑制干扰脉冲,并在脉冲丢失的情况下恢复脉冲序列的原始特征。相比之

下,TCN 网络能够更好地处理长时间序列数据,更好地捕捉序列之间的时间相关性。




图 10 不同脉冲丢失率 3 种方法识别结果

Fig. 10 Recognition results of different pulse loss rates for the three methods

5 结语

本文提出了一种基于 PDW 重构的智能机载雷达工作模式识别算法,利用脉冲序列重构结合 TCN 网络实现对于机载雷达空空状态的工作模式识别。解决了在脉冲丢失率高的情况下,雷达脉冲序列特征丢失和变形对于神经网络识别的影响,同时相比 CNN 网络,本文使用的 TCN 网络可以更好地处理长时序序列,捕捉序列中的时间相关性,大大地提高了对工作模式识别的准确率。经实验仿真验证,在高脉冲丢失率的情况下,本文的方法明显优于直接将未处理数据送入 TCN 网络和 CNN 网络,在脉冲丢失率小于 70% 的情况下,对于雷达工作模式的识别准确率能够达到 95% 以上。

参考文献

- [1] 周波,戴幻尧,乔会东,等. 基于“OODA 环”理论的认知电子战与赛博战探析[J]. 中国电子科学研究院学报, 2014, 9(6): 556-562.
- ZHOU B, DAI H Y, QIAO H D, et al. Research on Recognition EW and Cyberspace Operation Based on “OODA Loop” Theory[J]. Journal of China Academy of Electronics and Information Technology, 2014,

9(6): 556-562. (in Chinese)

- [2] 万海东,蔡伟,刘则林. 基于图像化特征的雷达信号个体识别与工作模式识别方法[J]. 空天预警研究学报, 2022, 36(2): 79-84.
- WAN H D, CAI W, LIU Z L. Method of Individual Recognition and Operating Mode Recognition of Radar Signal Based on Image Features[J]. Journal of Air & Space Early Warning Research, 2022, 36(2): 79-84. (in Chinese)
- [3] 王玉冰,程嗣怡,周一鹏,等. 基于 DS 证据理论的机载火控雷达空空工作模式判定[J]. 现代雷达, 2017, 39(5): 79-84.
- WANG Y B, CHENG S Y, ZHOU Y P, et al. Air-to-Air Operation Modes Recognition of Airborne Fire Control Radar Based on DS Evidence Theory[J]. Modern Radar, 2017, 39(5): 79-84. (in Chinese)
- [4] 唐文龙,张剑云,刘春生. 基于波位的对空情报雷达工作模式识别方法[J]. 现代雷达, 2017, 39(5): 17-20.
- TANG W L, ZHANG J Y, LIU C S. An Operational Mode Identification Method Based on Beam-Position Modeling for Three-Dimensional Air Surveillance Radar[J]. Modern Radar, 2017, 39(5): 17-20. (in Chinese)
- [5] 刘高高,黄东杰,席昕,等. 一种特征融合的工作模式识别方法[J]. 西安电子科技大学学报, 2023, 50(6): 13-20.

- LIU G G, HUANG D J, XI X, et al. Work Pattern Recognition Method Based on Feature Fusion[J]. Journal of Xidian University, 2023, 50(6): 13-20. (in Chinese)
- [6] 马珂,毕大平. 机载火控雷达空空工作状态识别研究[J]. 雷达科学与技术, 2021, 19(6): 697-703, 708.
- MA K, BI D P. Research on Air-to-Air Working State Recognition of Airborne Fire Control Radar[J]. Radar Science and Technology, 2021, 19(6): 697-703, 708. (in Chinese)
- [7] INGLIS J, SHAFER G. A Mathematical Theory of Evidence[J]. Technometrics, 1978, 20(1): 106.
- [8] 唐玉文,何明浩,韩俊,等. 基于复合赋权 TOPSIS 的雷达工作模式识别[J]. 中国电子科学研究院学报, 2019, 14(2): 196-202.
- TANG Y W, HE M H, HAN J, et al. Radar Operation Mode Recognition Based on Composite Weighted TOPSIS[J]. Journal of China Academy of Electronics and Information Technology, 2019, 14(2): 196-202. (in Chinese)
- [9] 程远国,张碧莹,封皓君. 关联分类 CBA 算法识别机载火控雷达工作模式[J]. 海军工程大学学报, 2022, 34(4): 1-6.
- CHENG Y G, ZHANG B Y, FENG H J. Operation Modes Recognition of Airborne Fire Control Radar Based on CBA Algorithm[J]. Journal of Naval University of Engineering, 2022, 34(4): 1-6. (in Chinese)
- [10] LI H, JIN W D, LIU H D, et al. Work Mode Identification of Airborne Phased Array Radar Based on the Combination of Multi-Level Modeling and Deep Learning[C]//2016 35th Chinese Control Conference (CCC). Chengdu: IEEE, 2016: 7005-7010.
- [11] DU M Y, ZHONG P, CAI X H, et al. Robust Bayesian Attention Belief Network for Radar Work Mode Recognition [J]. Digital Signal Processing, 2023, 133: 103874.
- [12] TIAN T, ZHANG Q R, ZHANG Z Z, et al. Shipborne Multi-Function Radar Working Mode Recognition Based on DP-ATCN [J]. Remote Sensing, 2023, 15(13): 3415.
- [13] 马珂,毕大平,周圣桀,等. 基于 1DCNN 的机载火控雷达空空工作状态识别[J]. 现代雷达, 2023, 45(3): 17-23.
- MA K, BI D P, ZHOU S L, et al. Air-to-Air Working State Recognition of Airborne Fire Control Radar Based on 1DCNN[J]. Modern Radar, 2023, 45(3): 17-23. (in Chinese)
- [14] 卓奕弘,熊敬伟,潘继飞,等. 基于多尺度注意力机制 ResNet 的雷达工作模式识别[J]. 雷达科学与技术, 2024, 22(2): 170-179, 186.
- ZHUO Y H, XIONG J W, PAN J F, et al. Radar Working Mode Recognition Based on Multi-Scale Attention Mechanism ResNet [J]. Radar Science and Technology, 2024, 22(2): 170-179, 186. (in Chinese)
- [15] 利强,张伟,金秋园,等. 基于知识原型网络的小样本多功能雷达工作模式识别[J]. 电子学报, 2022, 50(6): 1344-1350.
- LI Q, ZHANG W, JIN Q Y, et al. Multi-Function Radar Working Mode Recognition with Few Samples Based on Knowledge Embedded Prototype Network [J]. Acta Electronica Sinica, 2022, 50(6): 1344-1350. (in Chinese)
- [16] 唐玉文,何明浩,韩俊,等. 机载火控雷达典型空-空工作模式浅析[J]. 现代防御技术, 2018, 46(6): 87-93, 101.
- TANG Y W, HE M H, HAN J, et al. Typical Air to Air Operation Modes of Airborne Fire Control Radar [J]. Modern Defence Technology, 2018, 46(6): 87-93, 101. (in Chinese)
- [17] 阳榴,朱卫纲,吕守业,等. 多功能雷达工作模式识别方法综述[J]. 电讯技术, 2020, 60(11): 1384-1390.
- YANG L, ZHU W G, LYU S Y, et al. Review of Multi-Function Radar Mode Identification Methods [J]. Telecommunication Engineering, 2020, 60(11): 1384-1390. (in Chinese)
- [18] 金涛,王晓峰,田润澜,等. 基于改进 1DCNN+TCN 的雷达辐射源快速识别方法[J]. 系统工程与电子技术, 2022, 44(2): 463-469.
- JIN T, WANG X F, TIAN R L, et al. Rapid Recognition Method of Radar Emitter Based on Improved 1DCNN+TCN [J]. Systems Engineering and Electronics, 2022, 44(2): 463-469. (in Chinese)
- [19] LI X Q, HUANG Z T, WANG F H, et al. Toward Convolutional Neural Networks on Pulse Repetition Interval Modulation Recognition[J]. IEEE Communications Letters, 2018, 22(11): 2286-2289.

(编辑:陈斐)