

# 基于圆周积分样本的 Resnet1D 雷达 工作模式识别

刘 学<sup>1</sup>, 富云宵<sup>2</sup>, 徐洪洲<sup>1</sup>

(1. 中国人民解放军 91550 部队 94 分队, 辽宁 大连 116023;

2. 哈尔滨工程大学 信息与通信工程学院, 哈尔滨 150001)

**摘要:** 针对传统的机器学习算法对脉冲描述字表征的雷达工作模式进行学习与识别时, 存在对脉冲描述字捕获的准确率具有较高的依赖性以及识别准确率有限的问题; 提出了一种基于圆周积分样本的 Resnet1D 模型的雷达工作模式识别方法; 该方法采用积分双谱提取雷达工作模式的原始电磁信号高维表征样本特征, 在保留电磁信号相位和幅度信息的同时, 也实现了数据维度从二维至一维的降低; 降低计算复杂度的同时不会丢失雷达工作模式携带的电磁信号特征信息; 通过对比积分双谱特征, 计算机仿真表明圆周积分特征具有较好的识别准确率, 在信噪比 0 dB 条件下识别准确率超过 95%。

**关键词:** 雷达工作模式识别; 积分双谱; 深度学习; Resnet1D 网络; 多功能雷达

## Resnet1D Radar Mode Recognition of Operation Based on Circular Integral Samples

LIU Xue<sup>1</sup>, FU Yunxiao<sup>2</sup>, XU Hongzhou<sup>1</sup>

(1. Sub Unit 94, Unit 91550, PLA, Dalian 116023, China;

2. School of Communication and Information Engineering, Harbin Engineering University,  
Harbin 150001, China)

**Abstract:** Traditional traditional machine learning algorithms are used to learn and recognize the operating mode of a radar characterized by pulse descriptors, which have the problems of high dependence on the accuracy of pulse descriptor capturing and limited recognition accuracy. A radar operating mode recognition method based on the Resnet1D model with circular integral samples is proposed. The method uses an integral bispectrum to extract the high-dimensional characterization sample features of the original electromagnetic signal of the radar operating mode, which also achieves a reduction in the data dimension from two-dimensional to one-dimensional while retaining the phase and amplitude information of the electromagnetic signal, thus reducing computational complexity without losing the electromagnetic signal feature information carried by the radar operating mode. By comparing the integral bispectral features, computer simulation shows that with a signal-to-noise ratio of 0 dB, the circumferential integral features have a good recognition accuracy of over 95%.

**Keywords:** radar behavior recognition; integral bispectral; deep learning; Resnet1D; multi-functional radar

## 0 引言

随着科技的迅猛发展, 相控阵雷达日益先进, 其工作模式复杂多变。同时, 实际战争中的电磁对抗环境也

越发复杂<sup>[1-3]</sup>。传统雷达系统主要依靠操作人员的经验与技能来识别目标工作模式, 然而, 这种方式效率低下且易出现错误。

基于雷达工作模式的信号特性, 恰当选择分类特征

收稿日期:2024-10-27; 修回日期:2024-12-11。

基金项目:国家自然科学基金(61801482);博士后特别资助项目(2020T130772)

作者简介:刘 学(1983-),男,博士,高级工程师。

通讯作者:富云宵(1997-),男,硕士。

引用格式:刘 学,富云宵,徐洪洲.基于圆周积分样本的 Resnet1D 雷达工作模式识别[J].计算机测量与控制,2025,33(11):

267-273.

并设计分类器乃是工作模式识别的要点所在。方佳璐通过自适应滑动窗口对相参处理时间进行划分,进而有效地提取出雷达信号的特征,具有窗口划分自适应能力而且能纠正误判<sup>[4]</sup>。Jukka-Pekka Kaupp 别出心裁地运用动态边界划分的方法对脉冲重复间隔予以处理,构建出新的脉冲描述字,最终顺利实现了对雷达辐射源的识别,其特征区分能力强,分类准确率高,适用于复杂雷达信号的识别<sup>[5]</sup>。陈沛铂、李纲等人鉴于雷达脉冲在传输进程中可能由于各类内外因素而引发的瞬时幅度与频率弯折情况,独具匠心地采用动态时间规整算法加以校正,进而精确地达成了两者之间的距离测度<sup>[6]</sup>。但是该方法因为数据融合线性压缩会使得隶属度间距变小,影响识别准确性。RU Xiaohu 等人对民航雷达数据展开了深入细致的分析,他们察觉到雷达脉冲的瞬时幅度和频率曲线在前后沿呈现出优良的稳定性<sup>[7]</sup>。这种方法仅适用于二次雷达系统,且需要大量相似的辐射源个体存在。雷达信号的时域特性还涵盖载频的均值与方差、频率漂移曲线以及包络高阶矩特征等,这些特征在雷达信号的处理和识别过程中均起着至关重要的作用<sup>[8-10]</sup>。

现代电子侦察领域的一个研究热点是利用人工智能提升电子侦察装备的智能化水平,进而实现多功能雷达和认知雷达工作模式的识别<sup>[11-12]</sup>。目前,人工智能技术已逐步在分类任务<sup>[13-15]</sup>、语音信号域处理<sup>[16-17]</sup>、语义分割<sup>[18]</sup>以及信号和目标检测<sup>[19-21]</sup>等众多领域得到应用。以卷积神经网络(CNN, convolutional neural network)为主干的模型在挖掘信号特征方面表现出色,且应用广泛<sup>[22-24]</sup>。不过,这种方法存在局限性,对可变脉冲信号的适应性较弱。相比之下,循环神经网络在该问题上表现良好,在提取时间序列特征方面能力很强,在信号处理领域也有很多应用<sup>[25]</sup>。循环神经网络(RNN, recurrent neural network)族中的长短期记忆神经网络(LSTM, long short-term memory)和门控循环单元(GRU, gated recurrent unit)模型的训练过程比较艰难,需要很长时间才能使模型收敛,而且这类神经网络结构无法并行化。而注意力机制可以改善这一问题,使神经网络能够自动学习并选择性地关注输入中的重要信息,从而提高模型的性能和泛化能力。

随着电子侦察装备智能化水平的不断提升,卷积神经网络和循环神经网络等技术在雷达工作模式识别中发挥着重要作用。这些研究为现代电子侦察领域的发展提供了新的思路和方法。本文以大样本条件先验知识为背景,构建改进后的智能模型,来完成雷达工作模式识别的任务。

## 1 相控阵雷达工作模式信号

多功能雷达的工作模式复杂多样,即使处于同一工

作模式,其参数信息也并非完全一致,不过通常都在特定的范围内变动。众多参数与雷达工作模式紧密相连,其中包括载频、脉冲重复频率、脉冲宽度和占空比等。以多功能相控阵雷达的工作状态及原理为参照,能够确定不同工作状态下脉冲信号发射参数的特点。在本文中,所有的雷达信号均运用线性调频方式,线性调频的原理如公式:

$$s(t) = a(t) \exp[j\pi(B/\tau)t^2] + \epsilon(t) \quad (1)$$

其中:  $a(t)$  为信号瞬时幅度值,  $B$  为信号带宽,  $\tau$  为雷达信号脉冲宽度,  $\epsilon(t)$  是加入信号的均值为 0、方差为的高斯白噪声, 脉冲幅度信息在传输中受到噪声干扰较大,且会受到雷达发射机功率大小的影响,与雷达辐射源工作状态关联不大,因此本文中假定  $a(t)$  恒为 1。

相控阵雷达会根据实际场景的具体情况切换至不同的工作模式,以完成当前的任务。不同的任务需求对应着特定的工作模式,像搜索状态、复合状态和跟踪状态等。在搜索状态下,雷达的主要任务是进行速度搜索,从而发现目标。复合状态则较为复杂,能够同时处理目标信息,并根据多目标的状态灵活地转换任务,其中包括边搜索边跟踪(TWS, tracking while searching)、搜索加跟踪(TAS, tracking and searching)等模式。在跟踪状态中,雷达专注于对目标的精确追踪,涵盖多目标跟踪(MTT, multi-target tracking)和单目标跟踪(STT, single-target tracking)。

当雷达处于不同的工作模式时,会选择与之对应的不同工作参数,比如载频、脉冲信号带宽、脉冲重复频率等波形参数。脉冲描述字反映出这些特征参数之间相互关联的内在联系。下面给出了这 4 种工作模式下的相关参数,如表 1 所示。

表 1 雷达工作模式参数

雷达工作模式	RF/MHz	PRF/kHz	PW/μs
TWS	2 700~3 300	100~300	10~30
TAS	3 000~4 600	100~500	2~5
MTT	3 400~4 000	4~400	5~20
STT	3 800~4 400	10~250	5~20

## 2 基于积分双谱的特征提取方法

### 2.1 基于双谱的谱估计理论

双谱的由来可以追溯到高阶谱分析的发展。在信号处理领域,传统的信号分析方法主要基于二阶统计量,如时域的相关函数和频域的功率谱。然而,这些方法在处理非高斯、非线性和非平稳信号时存在局限性。为了更全面地描述信号的特性,学者们开始研究高阶统计量,并引入了高阶谱的概念。

双谱作为三阶累积量的二维傅里叶变换,是高阶谱

分析中的一种重要工具。它能够提供比二阶统计量更丰富的信息, 包括信号的幅度、相位以及非线性特性等。双谱的引入使得我们能够更好地理解和分析复杂信号的内部结构。对于给定的信号, 首先计算其三阶累积量, 该累积量是一个二维函数, 描述了信号在不同频率分量之间的相关性。然后, 对这个二维函数进行傅里叶变换, 得到双谱。双谱是一个复数函数, 其幅度和相位分别表示了信号在不同频率分量上的能量分布和相位关系。

双谱是一个二维函数, 其计算量和存储量相对较大。为了降低计算复杂度和提高处理效率, 可以采用积分双谱方法将双谱转化为一维数据。积分双谱方法通过沿着特定的路径对双谱进行积分, 将二维数据压缩为一维数据, 从而便于后续的特征提取和分类处理。双谱作为高阶谱分析中的一种重要工具, 能够提供比二阶统计量更丰富的信息, 并在信号处理领域具有广泛的应用前景。通过双谱变换对包含几个脉冲的单个信号进行双谱变换, 提取特征信息。

高阶累积量必须是绝对可和的, 才能使其的傅里叶变换有意义。对于随机信号  $s(t)$ , 设其  $k$  阶累积量为  $c_{ks}(\tau_1, L, \tau_{k-1})$ , 且为绝对可和的, 如式:

$$\sum_{\tau_1=-\infty}^{+\infty} \cdots \sum_{\tau_{k-1}=-\infty}^{+\infty} |c_{ks}(\tau_1, \dots, \tau_{k-1})| < \infty \quad (2)$$

对其  $k$  阶累积量进行  $k-1$  维的离散傅里叶变换, 如式:

$$S_{ks}(\omega_1, \dots, \omega_{k-1}) = \sum_{\tau_1=-\infty}^{+\infty} \cdots \sum_{\tau_{k-1}=-\infty}^{+\infty} c_{ks}(\tau_1, \dots, \tau_{k-1}) \cdot e^{-j(\omega_1 \tau_1 + \dots + \omega_{k-1} \tau_{k-1})} \quad (3)$$

式 (3) 为高阶累积量的谱, 即为高阶谱, 表示多个频率的谱。在实际的信号分析中常用的是三阶谱和四阶谱, 其中三阶谱  $S_{3s}(\omega_1, \omega_2)$  被称为双谱, 一般用  $B_s(\omega_1, \omega_2)$  表示, 四阶谱  $S_{4s}(\omega_1, \omega_2, \omega_3)$  被称为三谱, 一般用  $T_s(\omega_1, \omega_2, \omega_3)$  表示。

根据以上定义过程, 随机信号  $S(t)$  的双谱的定义如公式:

$$B_s(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{+\infty} \sum_{\tau_2=-\infty}^{+\infty} c_{3s}(\tau_1, \tau_2) e^{-j2\pi(\omega_1 \tau_1 + \omega_2 \tau_2)} \quad (4)$$

双谱具有如下性质:

1) 双谱  $B_s(\omega_1, \omega_2)$  一般是一个复数, 具有幅度信息和相位信息, 即:

$$B_s(\omega_1, \omega_2) = |B_s(\omega_1, \omega_2)| B_s(\omega_1, \omega_2) e^{j\phi_B(\omega_1, \omega_2)} \quad (5)$$

式中,  $|B_s(\omega_1, \omega_2)|$  表示双谱的幅度,  $\phi_B(\omega_1, \omega_2)$  表示双谱的相位。

2) 双谱是双周期函数, 两个周期均为  $2\pi$ , 即:

$$B_s(\omega_1, \omega_2) = B_s(\omega_1 + 2\pi, \omega_2 + 2\pi) \quad (6)$$

在频率域上, 双谱的值会周期性地重复出现。通过

在不同周期内观察双谱的变化规律, 可以更全面地了解信号的频率特性和动态行为。

3) 对称性。在直角坐标系中, 双谱具有 6 条对称线, 即:

$$\begin{aligned} B_s(\omega_1, \omega_2) &= B_s(\omega_2, \omega_1) = B_s^*(-\omega_1, -\omega_2) = \\ B_s^*(-\omega_2, -\omega_1) &= B_s(-\omega_1 - \omega_2, \omega_2) = \\ B_s(\omega_1, -\omega_1 - \omega_2) &= B_s(-\omega_1 - \omega_2, \omega_1) = \\ B_s(\omega_2, -\omega_1 - \omega_2) & \end{aligned} \quad (7)$$

对称性简化了双谱的计算过程, 通过对称性, 可以推断出信号中不同频率成分之间的相互作用和关联, 从而更准确地揭示信号的内在规律。

## 2.2 积分序列信息提取

双谱作为高阶谱的一种形式, 可揭示信号的相位和幅度信息, 为信号的特征提取及分类提供有力支持。然而, 双谱分析得出的数据通常是二维的, 这在处理时会导致计算复杂且存储需求较大的问题。针对此问题, 研究者们提出了不同的积分双谱方法, 其中有轴向积分双谱 (AIB, axial integral bispectrum)、圆周积分双谱 (CIB, circle integral bispectrum) 和矩形积分双谱 (SIB, square integral bispectrum) 3 种积分。这种降维处理举措不仅使后续信号处理流程得以简化, 还极大地提高了处理效率。这 3 种积分路径的原理示意图如图 1 所示。

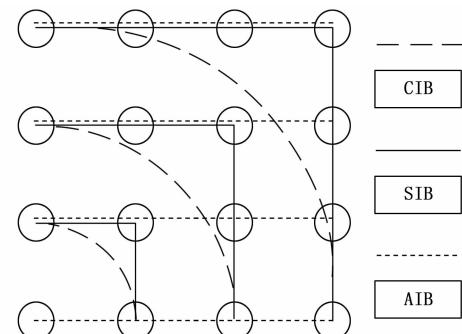


图 1 3 种积分路径

AIB 是通过沿着双谱矩阵的坐标轴方向进行积分来获得一维特征的方法。

AIB 常常在一些信号分析场景中得到应用, 这些信号的频率成分在特定轴上具有显著的分布特征, 像机械振动信号以及语音信号之类。借助 AIB 这种方法, 可以提取出信号在不同频率轴上的能量分布特点, 在诸如故障诊断、语音识别等任务里发挥重要作用。假设信号  $s(t)$  变换后的双谱为  $B(\omega_1, \omega_2)$ , AIB 的定义如公式:

$$AIB(\omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} B(\omega, \omega_2) d\omega_2 = \frac{1}{2\pi} \int_{-\infty}^{+\infty} B(\omega_1, \omega) d\omega_1 \quad (8)$$

SIB 基本原理是通过特定的矩形积分路径对双谱进行积分, 从双谱信息中提取出有用的特征, 同时降低数据维度, 简化后续的处理过程。该积分方式不会出现双谱值遗漏的情况, 确保了信息的完整性。矩形积分双谱特征具有时移不变性, 还保持了信号的尺度信息和相位信息, 这些信息对于信号的特征提取和分类识别等任务至关重要。

SIB 适宜于那些需要着重关注特定频率范围内信号特性的应用场合。SIB 的积分路径是一组以原点为核心的正方形, 其定义式如公式所示:

$$SIB(\omega) = \oint_{S_i} B(\omega_1, \omega_2) d\omega_1 d\omega_2 \quad (9)$$

式中,  $S_i$  表示矩形积分路径。

CIB 乃是通过在双谱平面上以原点作为中心, 沿着不同半径的圆周路径来进行积分的一种方法。此方法可以提取出信号在不同频率比例下的相位以及幅度信息。CIB 适用于具有明显周期性或旋转对称性的信号分析, 如旋转机械的振动信号、图像处理中的纹理分析等。通过 CIB, 可以提取出信号在不同频率比例下的相位和幅度特征, 用于识别不同的周期性模式或纹理结构。令双谱  $B(\omega_1, \omega_2)$  在极坐标下的表示为  $B_p(R, \theta)$ , 其中  $r$  表示极坐标下的半径,  $\theta$  为角度, 则有  $\omega_1 = r\cos\theta$ ,  $\omega_2 = r\sin\theta$ , 圆周积分双谱定义如公式:

$$CIB(r) = \int B_p(r, \theta) d\theta \quad (10)$$

### 3 基于 Resnet1D 的雷达工作模式识别

#### 3.1 残差网络模型

ResNet 网络采用跨层残差连接操作, 极大地改善了深度神经网络中梯度消失和梯度爆炸的问题, 因此深层神经网络能够更容易地训练和优化。在传统神经网络中, 为追求更高的识别效果常常增加网络层数, 但随着层数增加, 梯度消失和梯度爆炸等问题也会接踵而至。而残差连接的引入, 在不带来额外参数和增加计算复杂度的情况下, 能够使网络深度增加, 有效避免梯度消失和梯度爆炸问题, 进而提高网络性能。相比传统网络, ResNet 网络的性能更为优越。残差块结构图如图 2 所示。

其中  $x$  是残差网络的输入,  $F(x)$  是其对应的残差映射,  $H(x)$  是输出。一般的神经网络结构都是训练学习  $H(x)$  的输入、输出映射, 但是残差神经网络则是对  $F(x) = H(x) - x$  映射函数的学习, 可以避免从  $x$  到  $H(x)$  进行直接映射。残差将输出与输入连接, 既保留了原有输入特征, 又保留了网络处理后的结果。由图 2 可以看出, 残差神经网络的残差块主要由卷积层和激活函数组成, 其中激活函数选用的是 RELU。

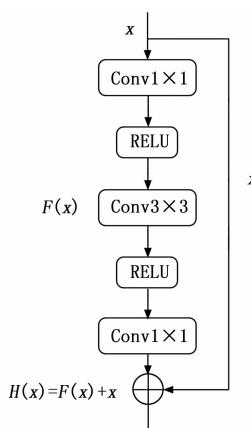


图 2 残差块结构

当输入和残差块映射出来的数据维度不同时, 此时需要将输入  $x$  的通过  $1 \times 1$  卷积转换成同维度的数据, 此时残差块的输出如下:

$$y = f(F(x, w_n) + x \cdot w_n) \quad (11)$$

其中:  $f(g)$  是激活函数,  $w_n$  是残差函数对应的权重。激活函数通过函数把特征保留并映射出来, 即负责将神经元的输入映射到输出端。

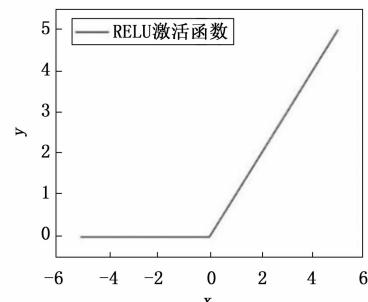


图 3 RELU 激活函数

RELU 在很大程度上成功解决了梯度消失问题, 并且能够有效处理神经网络在学习过程中出现的过拟合情况。它将输入数值进行映射, 范围是从 0 到正无穷。当输入数值为负值时, 不会进行任何映射。RELU 函数在大于 0 的部分, 其梯度为常数, 因此不会产生梯度弥散现象。

#### 3.2 基于 Resnet1D 的雷达工作模式识别

前文介绍了双谱矩阵在信号处理方面的情况。鉴于双谱呈矩阵形式, 数据量颇为庞大, 若直接将其输入网络模型, 计算量会非常大, 难以满足实时性的要求。所以, 采用 AIB、CIB、SIB 这 3 种积分方式来降低数据维度, 把矩阵转化为长序列特征信息。对于本文从信号中提取出的特征信息, 运用 ResNet1D 的残差网络对输入特征进行处理并实现与标签的映射。

特征提取部分主要是由两个残差结构串联而成, 属

于一维残差网络, 其主要功能在于对输入数据进行特征提取。因为 CIB、SIB 和 AIB 数据均  $1 \times 128$  是的特定向量, 所以在第一个残差块中设计通道数为 1, 设定卷积核大小为  $1 \times 1$ , 卷积步长为 1。其中, 压缩系数会随着层的深度不断增加而增大, 接着对卷积后的结果进行归一化处理, 最后通过 ReLU 激活函数进行激活。重复上述操作, 从而完成两个残差结构的数据处理。

在网络层的后续层训练过程中, 输入数据的分布始终在发生变化。前面层训练参数的更新会引发后面层输入数据分布的改变。因为每批训练数据的分布各不相同, 所以网络需要在每次迭代中去学习适应不同的分布, 这样一来, 网络的训练速度就会大幅降低。批量归一化能够去除特征之间的相关性, 并且让所有特征具有相同的均值和方差, 从而加快运算速度。Softmax 分类模块对第二部分中已经提取出的重要特征信息进行分类。

在图 4 中, 一维残差块的设计充分考虑一维信号的特点并进行优化。它对输入信息运用一系列操作, 包括卷积、批标准化和非线性激活函数等, 从而有效地提取信号中的时序信息。采用两层残差块的设计策略具有重要意义。一方面, 能够在减少网络参数量和计算量的同时, 维持模型的表达能力; 另一方面, 这也回应了深度学习模型通常面临的挑战, 即在有限的计算资源下实现高效的特征学习。后续的 Softmax 分类模块根据前面全连接层所再次提取的深度特征进行分类识别任务, 完成对雷达模式的匹配和输出。

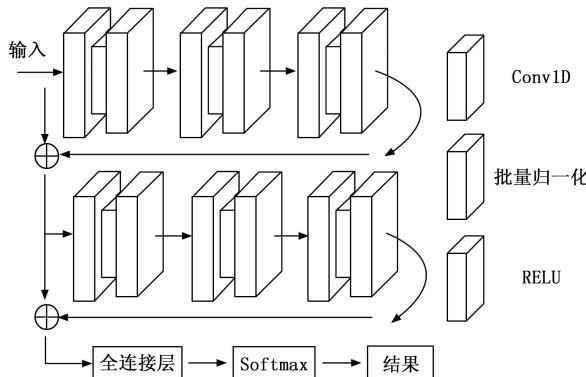


图 4 基于 ResNet1D 的一维残差神经网络结构

设计的两层残差块使得模型在降低计算负担之际, 依然能够高效地提取和处理信号中的复杂特征。经过处理后的这些特征信息会被传递给一个分类器, 以便将高维特征空间中的数据点映射到预定义的类别上, 进而实现信号的分类与识别。

综上所述, 该结构借助一维残差块的运用, 成功有效地捕捉到了一维信号中的时序信息, 提升了模型的建模能力。同时, 通过两层残差块的设计, 达成了网络参

数量和计算量的减少与模型表达能力之间的平衡。凭借分类器的运用, 实现了对信号特征的准确提取以及分类识别。在处理复杂的一维信号数据时, 这一结构展现出了卓越的性能。

## 4 实验结果分析

### 4.1 雷达工作模式信号波形仿真

对 TWS、TAS、MTT、STT 这 4 种典型的雷达工作模式进行波形仿真, 根据公开文献设定的参数及原理, 仿真 4 种工作模式下的波形, 如表 1 所示。

如图 5, TWS 工作模式下跟踪数据率与搜索数据率相等。TWS 工作模式选取参数信息如下, 载频 2 000 MHz, 脉冲重复频率为 100 kHz, 脉冲宽度 10  $\mu$ s, 天线增益 38 dB, 信噪比 10 dB。

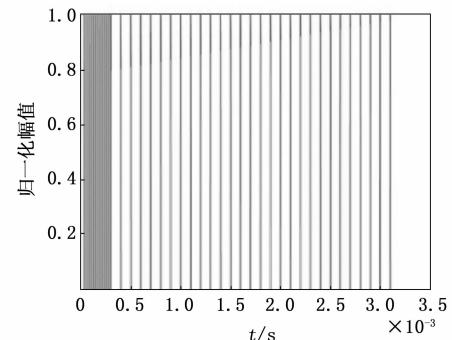


图 5 TWS 工作模式波形图

如图 6, TAS 工作模式在任务周期中交替执行对目标空域的搜索和跟踪任务。一般而言, TAS 模式下跟踪数据率比搜索数据率大。设定脉冲重复频率为 3 000 MHz, 脉冲宽度 2  $\mu$ s, 天线增益 38 dB, 信噪比 10 dB。

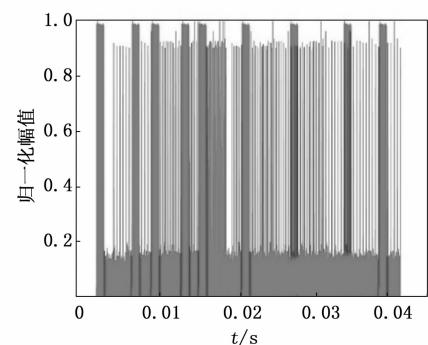


图 6 TAS 工作模式波形图

MTT 工作模式下, 相控阵雷达通过对多个目标的信息进行关联和处理, 能够实现对多个目标的精确跟踪, 并且有效地降低了跟丢目标的概率。MTT 工作模式的威胁等级高于 TAS 工作模式。设定脉冲重复频率为 4 kHz, 脉冲宽度 10  $\mu$ s, 天线增益 38 dB, 信噪比 10 dB。多目标跟踪工作模式波形仿真图如图 7。

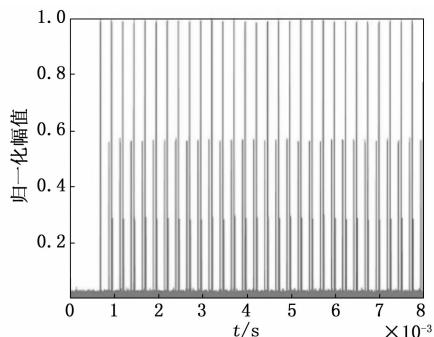


图 7 MTT 工作模式波形图

当雷达进入 STT 模式时, 雷达会调动其全部资源, 针对单一目标展开密切而精准的跟踪。这种模式的操作过程首先是从雷达依据先验信息对空域中的目标进行小范围搜索开始的。作为威胁等级最高的工作模式, STT 模式下跟踪数据率比 MTT 模式更高。设定参数如下, 脉冲重复频率为 10 kHz, 脉宽 10  $\mu$ s, 天线增益 33 dB。单目标跟踪工作模式波形仿真图如图 8 所示。

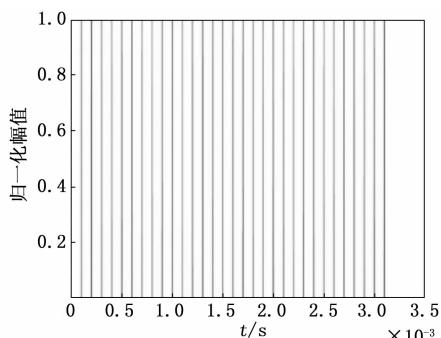


图 8 STT 工作模式波形图

#### 4.2 雷达工作模式识别结果分析

首先, 依据上一节的信号处理及识别模型来搭建识别架构。接着, 在谷歌云平台上进行建模与仿真。设置两块残差块, 采用 RELU 作为激活函数。实验参数方面, 将训练轮次定为 800 次, 学习率设为 0.002 5, 优化函数确定为 Adam, 同时利用 L2 正则项来约束模型复杂度。把经过双谱处理以及 AIB、CIB、SIB 3 种积分方式处理后的序列信息作为输入, 通过模型进行深度特征提取并进行标签映射。每种积分方式下有 800 条特征序列。3 种积分方式下的模型损失曲线及识别准确率如图 9 所示。

图 9 呈现的情况是, 除了 -20 dB 下的 SIB 损失曲线之外, 其余的损失曲线在经过 100 次迭代后, 都快速地收敛, 并且趋向于 0。其中, 20 dB 下的 CIB 曲线收敛速度最为迅速, 损失值也是最小的。对图中的观测点 1 和观测点 2 进行局部放大观察。从图中可以看出, CIB 曲线的识别效果要比 AIB 和 SIB 更好。为了更加深

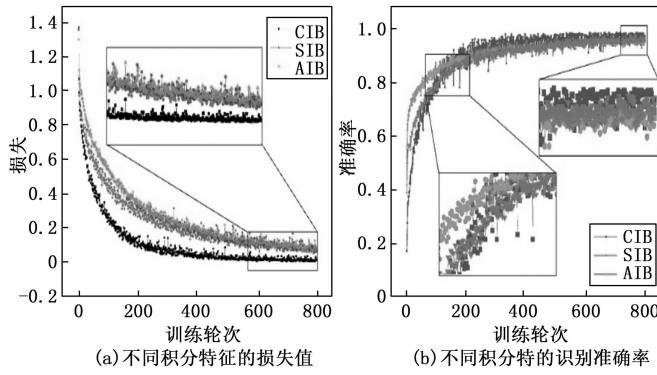


图 9 不同积分方式下的模型损失值及识别准确率

入地探究 3 种积分方式的识别效果, 对处于 -20 dB 信噪比至 30 dB 信噪比范围内的 3 种积分方式开展识别工作。其识别效果图如图 10 所示。

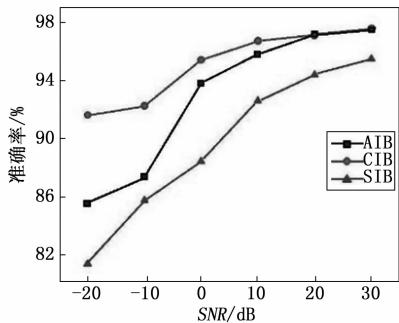


图 10 不同积分方式识别准确率

在 3 种积分方式当中, SIB 积分方式的表现最为逊色。无论在何种信噪比条件下, 它的效果都不及 AIB 和 CIB。AIB 积分方式的成效处于 CIB 和 SIB 之间。当信噪比达到 20 dB 及以上时, AIB 与 CIB 的识别效果大致相同。而 CIB 曲线在 -20 dB 信噪比下, 识别准确率高于 90%, 在 3 种积分方式里效果最为卓越。

#### 5 结束语

在样本量足够的时候, 传统方法通常会利用基于雷达脉冲描述字的特征表征信息作为分类器的原始输入。只是这类方法过于依赖对雷达脉冲描述字的捕获准确率, 在对抗方的雷达模式过于复杂的情况下, 对雷达模式识别的性能影响较大。本文通过引入深度学习的方法, 提出一种以一维特征信息为输入的 Resnet1D 模型, 对雷达模式的原始电磁信号进行积分双谱以对双谱特征进行降维的特征提取, 避免了直接使用双谱作为输入计算量过大的问题, 同时提取了原始信号中更为本质和全面的信息, 采用了 3 种积分方式降低特征维度作为对比。为了验证本文所提方法的有效性, 通过仿真实验对比了 3 种不同的积分方式下该网络结构对雷达模式识别的准确率, 并且通过详细的实验分析和数据对比, 发现

CIB积分方式下的雷达模式识别方法对本文数据提取特征时可以获得到了较高的准确性。

### 参考文献:

- [1] 王增福,杨广宇,金术玲.考虑综合性能最优的非短视快速天基雷达多目标跟踪资源调度算法[J].雷达学报,2024,13(1):253-269.
- [2] 汪翔,汪育苗,陈星宇,等.基于深度学习的多特征融合海面目标检测方法[J].雷达学报,2024,12:1-11.
- [3] 曲志昱,李根,邓志安.基于知识蒸馏与注意力图的雷达信号识别方法[J].电子与信息学报,2022,44(9):3170-3177.
- [4] 方佳璐.雷达信号工作模式识别研究[D].杭州:浙江大学,2017.
- [5] KAUPPI J-P, MARTIKAINEN K, RUOTSALAINEN U. Hierarchical classification of dynamically varying radar pulse repetition interval modulation patterns [J]. Neural Networks, 2010, 23(10): 1226-1237.
- [6] 陈沛铂,李纲.应用动态时间规整算法实现雷达辐射源个体识别[J].Journal of Signal Processing, 2015, 31(8): 1035-1040.
- [7] RU X, YE H, LIU Z, et al. An experimental study on secondary radar transponder UMOP characteristics [C] // 2016 European Radar Conference, IEEE, 2016: 314-317.
- [8] 蒋鹏.雷达信号细微特征分析与识别[D].哈尔滨:哈尔滨工程大学,2012.
- [9] Zhao Y, Wui L, Zhang J, et al. Specific emitter identification using geometric features of frequency drift curve [J]. Bulletin of the Polish Academy of Sciences. Technical Sciences, 2018, 66(1): 99-108.
- [10] 王宏伟,赵国庆,王玉军.基于脉冲包络前沿高阶矩特征的辐射源个体识别[J].现代雷达,2010,32(10):42-45.
- [11] ZHANG Z L, LI Y, ZHAI Q H, et al. Mode recognition of multifunction radars for few-shot learning based on compound alignments [J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(6): 5860-5874.
- [12] LORAN T, DASILVA A B C, JOSHI S K, et al. Ship detection based on faster R-CNN using range-compressed airborne radar data [J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 3500205.
- [13] LOCONSOLE C, CASCARANO G D, BRUNETTI A, et al. A model-free technique based on computer vision and SEMG for the classification in Parkinson's disease by using computer-assisted handwriting analysis [J]. Pattern Recognition Letters, 2018, 18(6): 28-39.
- [14] KUSSUL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 778-782.
- [15] ZHANG S H, LU X L, LU Z J. Improved CNN-based CatBoost model for license plate remote sensing image classification [J]. Signal Processing, 2023, 213: 109196.
- [16] ZHANG Y H, TU X T, LIANG H, et al. Learning to sound imaging by a model-based interpretable network [J]. Signal Processing, 2014, 215: 109281.
- [17] GAO Y, ZHOU Y, WANG Y, et al. Narrowband radar automatic target recognition based on a hierarchical fusing network with multidomain features [J]. IEEE Geoscience and Remote Sensing Letters, 2021, 18(6): 1039-1043.
- [18] MIRAMONT J M, AUGER F, COLOMINAS M A, et al. Unsupervised classification of the spectrogram zeros with an application to signal detection and denoising [J]. Signal Processing, 2024, 214: 109250.
- [19] LIU Y, ZHANG Y Z, LIU S C, et al. Salient object detection by aggregating contextual information [J]. Pattern Recognition Letters, 2021, 153: 190-199.
- [20] ZHAO J H, XU S, WANG R Q, et al. Data-Adaptive binary neural networks for efficient object detection and recognition [J]. Pattern Recognition Letters, 2021, 153: 239-245.
- [21] BARÓ A, RIBA P, ZARAGOZA J C, et al. From optical music recognition to handwritten music recognition: a baseline [J]. Pattern Recognition Letters, 2019, 123: 1-8.
- [22] JOYSINGH S J, VIJAYALAKSHMI P, NAGARAJAN T. Quartered spectral envelope and 1D-CNN-based classification of normally phonated and whispered speech [J]. Circuits, Systems, and Signal Processing, 2023, 42(5): 3038-3053.
- [23] LI X, HUANG Z, WANG F, et al. Toward convolutional neural networks on pulse repetition interval modulation recognition [J]. IEEE Communications Letters, 2018, 22(11): 2286-2289.
- [24] QU Q, WEI S, WU Y, et al. ACSE networks and auto-correlation features for PRI modulation recognition [J]. IEEE Communications Letters, 2020, 24(8): 1729-1733.
- [25] LIU Z M, PHILIP S Y. Classification, denoising, and deinterleaving of pulse streams with recurrent neural networks [J]. IEEE Transactions on Aerospace and Electronic Systems, 2018, 55(4): 1624-1639.
- [26] 刘海军,雷东兴,袁静,等.基于注意力机制LSTM的电离层TEC预测[J].地球物理学报,2024,67(2):439-451.
- [27] ZENG J, YANG L. Speech enhancement of complex convolutional recurrent network with attention [J]. Circuits, Systems, and Signal Processing, 2023, 42(3): 1834-1847.