

DOI: 10.19650/j.cnki.cjsi.J2514481

# 基于多维特征时空融合网络的雷达 PRI 调制类型识别\*

张世成, 周 游, 年夫顺, 王宏硕, 韩顺利

(中国电子科技集团公司第四十一研究所电子测试技术重点实验室 青岛 266555)

**摘要:** 雷达信号的脉冲重复间隔 (PRI) 调制类型识别作为电子战系统信号分选与威胁评估的核心环节, 其识别精度直接决定战场电磁态势认知与对抗策略的生成效能。针对传统方法存在的专家经验依赖性强、单一模型特征提取能力不足等问题, 提出一种基于多维特征时空融合的深度神经网络架构。该方法通过构建卷积神经网络与长短时记忆网络的级联架构, 挖掘雷达脉冲时空特征与调制时序演化规律之间的内在关联性, 引入序列注意力机制对输出的时序特征进行加权融合, 突出 PRI 变化的关键时刻, 从而实现脉冲重复间隔调制类型的准确识别。实验基于包含固定、抖动、组变、参差和滑变 5 类典型调制信号的数据集进行验证, 结果表明, 在无干扰理想条件下, 模型整体识别准确率达 99.40%; 在高达 70% 的脉冲丢失干扰下, 识别准确率仍可达 70.93%; 在同等强度的虚假脉冲干扰下, 识别准确率高达 96.13%, 综合性能显著优于 CNN、CNN-LSTM、GRU-Attention 及 SE-NET 等主流对比模型, 有效提升了复杂电磁环境下 PRI 调制识别的精度与鲁棒性。此外, 模型单样本推理时间仅为 1.54 ms, 参数量为 653 814, 兼具良好的实时性与轻量化部署潜力。所提方法为复杂电磁环境下雷达 PRI 调制类型的实时、准确识别提供了有效的技术途径, 具有重要的理论价值与工程实用性。

**关键词:** PRI 调制; 脉冲丢失; 虚假脉冲; 卷积神经网络; 长短时记忆神经网络; 注意力机制

**中图分类号:** TH7 **文献标识码:** A **国家标准学科分类代码:** 510.70

## Radar PRI modulation recognition based on multi-dimensional feature space-time fusion network

Zhang Shicheng, Zhou You, Nian Fushun, Wang Hongshuo, Han Shunli

(Science and Technology on Electronic Test & Measurement Laboratory, The 41st Institute of China Electronic Technology Group Corporation, Qingdao 266555, China)

**Abstract:** Pulse repetition interval (PRI) modulation type recognition of radar signals is a critical component for signal sorting and threat assessment in electronic warfare systems, as its accuracy directly affects battlefield electromagnetic situational awareness and the effectiveness of countermeasure strategies. To address the limitations of traditional methods—namely, strong reliance on expert knowledge and insufficient feature extraction capacity of single models—this paper proposes a deep neural network architecture based on multi-dimensional feature space-time fusion. The approach constructs a cascade of convolutional neural networks (CNN) and long short-term memory (LSTM) networks to capture the intrinsic correlations between the spatiotemporal characteristics of radar pulses and the temporal evolution of modulation patterns. A sequential attention mechanism is incorporated to weight and fuse the extracted temporal features, emphasizing key moments of PRI variation and enabling accurate identification of PRI modulation types. Experiments are conducted on a dataset comprising five typical modulation types: Fixed, jitter, group change, stagger, and slip. Results show that, under ideal interference-free conditions, the model achieves an overall recognition accuracy of 99.40%. Even under 70% pulse loss interference, recognition accuracy remains 70.93%, and under equal-strength false pulse interference, it reaches 96.13%. The proposed model significantly outperforms mainstream comparison models, including CNN, CNN-LSTM, GRU-Attention, and SE-NET,

收稿日期: 2025-09-10 Received Date: 2025-09-10

\* 基金项目: 国家自然科学基金 (U24B6013) 项目资助

demonstrating enhanced accuracy and robustness in complex electromagnetic environments. Furthermore, the model requires only 1.54 ms for single-sample inference and has 653 814 parameters, offering strong real-time capability and potential for lightweight deployment. The proposed method provides an effective technical solution for real-time, accurate recognition of radar PRI modulation types in complex electromagnetic environments, with both theoretical significance and practical engineering applicability.

**Keywords:** PRI modulation; pulse loss; false pulse; convolutional neural network; long and short term memory network; attention mechanism

## 0 引言

雷达脉冲重复间隔(pulse repetition interval, PRI)作为雷达辐射源信号的核心参数<sup>[1-2]</sup>,可表征雷达信号的基本特征,推断雷达的工作模式。深入研究并精准识别PRI调制类型,对于雷达信号的分选、识别和态势感知具有重要意义<sup>[3-4]</sup>。在现代电磁环境中,雷达信号的复杂性不断增加,多种调制方式被广泛应用于雷达系统中,以满足特定的战术需求和提高抗干扰能力<sup>[5-6]</sup>。然而,这些复杂的调制方式也给雷达信号的识别带来了巨大的挑战。

传统的PRI调制类型识别方法主要包括直方图法、特征提取分析法等。直方图法<sup>[7-8]</sup>基于脉冲重复间隔的时域分布特征,通过量化统计不同时段内脉冲信号的频次分布规律,实现对常规脉冲重复间隔模式的识别与分类。常安琪等<sup>[9]</sup>基于符号化序列计算得到特征参数,通过分层识别的方式判断PRI序列的调制类型。刘峻臣等<sup>[10]</sup>利用密度聚类的思想去除无关脉冲,通过多特征联合匹配进行雷达PRI调制类型的识别。然而,当电磁环境趋于复杂时,传统方法计算复杂度高且严重依赖人工经验,应用场景受限。

近年来,随着人工智能算法的持续革新,基于深度学习的雷达信号表征与处理成为研究热点<sup>[11-12]</sup>。黄中瑞等<sup>[13]</sup>搭建卷积神经(convolutional neural network, CNN)网络自适应提取PRI序列的空间特征,从而对PRI调制类型进行识别。Li等<sup>[14]</sup>提出了一种基于门控循环单元(gated recurrent unit, GRU)的注意力机制识别框架,实现了对复杂PRI调制类型的识别。孟磊等<sup>[15]</sup>将长短期记忆网络(long short-term memory, LSTM)应用于PRI调制类型的识别,在脉冲丢失情况下具有良好的适应能力。Wei等<sup>[16]</sup>提出了一种基于挤压激励网络(squeeze-and-excitation networks, SE-NET)和自相关函数的PRI调制类型自动识别方法,将PRI调制类型特征转换为图像,通过挤压激励网络对PRI调制类型进行识别。但是,单一结构的深度学习模型难以充分挖掘复杂电磁干扰下雷达信号的时空关联特征,导致识别准确率不足。

针对上述两类方法的不足,本文提出一种融合CNN、LSTM与注意力机制(attention mechanism, AM)的多维特征融合识别方法。该方法结合CNN对空间特征的提取

能力和LSTM对时序特征的捕捉能力,并引入序列注意力机制自适应地强化对调制类型具有判别性的关键脉冲位置,实现对雷达PRI调制类型的高精度识别。

## 1 复杂体制雷达PRI调制类型

设经过分选后的雷达脉冲到达时间(time of arrival, TOA)为:

$$TOA = (t_1, t_2, \dots, t_N) \quad (1)$$

式中: $t_N$ 为第 $N$ 个脉冲信号到达时刻; $N$ 为信号脉冲个数。对TOA序列做一次差分,可以得出信号的脉冲重复间隔为:

$$p(i) = (t_{i+1} - t_i), \quad i = 1, 2, \dots, N \quad (2)$$

式中: $p(i)$ 为雷达信号的脉冲重复间隔,是雷达信号的固有特征参数。

根据雷达的功能及体制的不同,PRI调制方式也不一样,典型的PRI调制方式可分为5种:

1) 固定:PRI值不随时间变化,始终保持不变,抖动量不会超过固定值的1%,模型表达式为:

$$p(i) = p_0, \quad i = 1, 2, \dots, N \quad (3)$$

式中: $p_0$ 为固定脉冲重复间隔。

2) 抖动:PRI值随时间在一个中心值附近随机快速的跳动,抖动量一般在中心值的3%~30%,模型表达式为:

$$p(i) = p_c + \delta_i, \quad i = 1, 2, \dots, N \quad (4)$$

式中: $p_c$ 为脉冲重复间隔的中心值; $\delta_i$ 为第 $i$ 个PRI抖动量。

3) 组变:由多个固定的PRI值持续一定时间后转换,在周期内规律交替变化,模型表达式为:

$$p(i) = p_t, \quad p_t \in \{p_1, p_2, \dots, p_s\} \quad (5)$$

式中: $p_t$ 是 $\{p_1, p_2, \dots, p_s\}$ 中的值。

4) 参差:PRI存在多个固定的值,并按照一定的规律循环交替往复,模型表达式为:

$$p(i) = p_k, \quad t = i \bmod m; p_k \in \{p_1, p_2, \dots, p_m\} \quad (6)$$

式中: $\{p_1, p_2, \dots, p_m\}$ 为一个子周期; $\bmod$ 为取余函数。

5) 滑变:PRI值随时间按照步长递增或递减,达到最值后切换到初始值,模型表达式为:

$$p(i) = p_b + \theta \times (i \bmod M) \quad (7)$$

式中: $p_b$ 为PRI初始值; $\theta$ 为步长; $M$ 为帧周期内脉冲个数。

5种典型PRI调制类型和应用场景如表1所示。

表1 PRI调制规律和应用场景

Table 1 PRI modulation patterns and application scenarios

类型	PRI调制规律	应用场景
固定	PRI恒定不变	应用于常规搜索和跟踪雷达
抖动	PRI在中心值范围内快速随机变化	降低脉冲到达时间特定干扰
组变	一个周期内存在多个子周期,多个子周期规律交替变换	脉冲多普勒雷达中消除距离糊、速度模糊的问题
参差	顺序循环排列的固定PRI	MTI系统中消除盲速
渐变	周期内PRI按照固定步长逐渐变大或减小	优化俯仰扫描,消除遮盖

在实际电磁对抗场景中,雷达脉冲信号易受多径效应、电磁干扰及传感器噪声等因素影响,导致脉冲丢失与虚假脉冲现象频发。

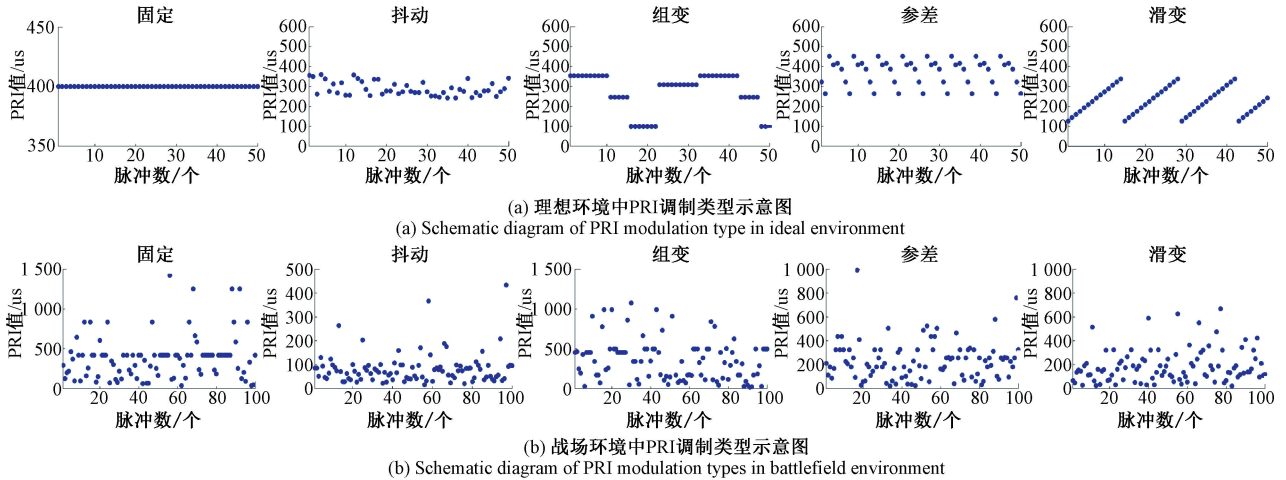


图1 5种典型的雷达PRI类型调制方式

Fig. 1 Five typical radar PRI modulation methods

## 2 雷达PRI调制类型识别方法

### 2.1 CNN

CNN网络<sup>[17]</sup>主要由输入层、卷积层、池化层、全连接层和输出层5部分组成。卷积层和池化层是整个模型结构的重点,卷积层包含多个卷积核,通过卷积运算提取雷达信号PRI序列的空间特征分布,卷积运算表达式为:

$$\mathbf{y}^k = \sum_{i=1}^{c^{k-1}} \mathbf{w}_{i,c}^k * \mathbf{x}_i^{k-1} + \mathbf{b}_i^k \quad (10)$$

在接收到的到达时间序列TOA中,第 $k$ 个脉冲到第 $k+j-1$ 个脉冲之间丢失了 $j$ 个脉冲时,新的脉冲识别码序列 $p'(i)$ 可表示为:

$$p'(i) = \begin{cases} p(i), & i = 1, 2, \dots, k-1 \\ p(k) + \dots + p(k+j-1), & i = k \\ p(i+j), & i = k+1, \dots, N-j-1 \end{cases} \quad (8)$$

对于虚假脉冲,若第 $k$ 个脉冲后加入了 $j$ 个脉冲,其一阶差分表示为 $g(t) = \{g(0), g(1), \dots, g(j)\}$ ,新的PRI序列 $p''(i)$ 为:

$$p''(i) = \begin{cases} p(i), & i = 1, 2, \dots, k-1 \\ g(i-k), & i = k, \dots, k+j \\ p(i-j), & i = k+j+1, \dots, N+j-1 \end{cases} \quad (9)$$

图1(a)展示了5种典型PRI调制类型在无干扰理想条件下的散点图;图1(b)则对应呈现了在脉冲丢失率与杂散脉冲率均高达50%的强干扰战场环境下的相同调制模式。

式中: $\mathbf{y}^k$ 为第 $k$ 层的输出; $\mathbf{c}^{k-1}$ 是 $k-1$ 层的 $\mathbf{c}$ 通道; $\mathbf{w}_{i,c}^k$ 为权重矩阵; $\mathbf{x}_i^{k-1}$ 为 $k-1$ 层的 $i$ 通道输出; $\mathbf{b}_i^k$ 为权重系数。

池化层通过池化运算对卷积后的数据特征进行降维处理,丢弃无用信息,聚合局部特征,从而降低参数量,缓解网络过拟合,提高模型的泛化性。最大池化计算表达式为:

$$\{\mathbf{y}^{k(i,j)} = \max_{(j-1)S+1 < t < jS} \{\mathbf{x}^{k(i,t)}\} \quad (11)$$

式中: $\mathbf{y}^{k(i,j)}$ 为 $k$ 层 $i$ 通道第 $j$ 个神经元; $S$ 为池化核的大小; $\mathbf{x}^{k(i,t)}$ 为 $k$ 层 $i$ 通道第 $t$ 个神经元。

在深度神经网络架构中,通过多层叠加卷积层和池化层以构建深度的网络结构。全连接层是一个密集连接的神经网络,能够根据各个神经元的不同贡献度,优化网络架构和各神经元间的权重,实现雷达 PRI 调制类型的分类任务的输出,具体网络结构如图 2 所示。




图 2 CNN 网络结构

Fig. 2 CNN network structure

### 2.2 LSTM

LSTM 内部设计了遗忘门、输入门和输出门多个门控机制来调节数据流。这些门控结构能够精准的管理序列中信息的流动,专门处理长期依赖的问题,甄别维护关键的数据片段。在序列的长跨度传递中,这些关键信息被有效保留用于预测。计算方法可以表示为:

$$f_t = \sigma(W_f[h_{t-1}, r_t] + b_f) \quad (12)$$

式中:  $f_t$  为遗忘门;  $W_f$  表示权重矩阵;  $b_f$  表示偏置量;  $h_{t-1}$  为  $t-1$  时刻隐藏层输出;  $r_t$  为当前时间步的输入。

$$i_t = \sigma(W_i \cdot [h_{t-1}, r_t] + b_i) \quad (13)$$

$$\hat{c}_t = \tanh(W_c \cdot [h_{t-1}, r_t] + b_c)$$

$$c_t = c_{t-1} \cdot f_t + \hat{c}_t \cdot i_t$$

式中:  $i_t$  为输入门;  $W_i$  和  $W_c$  表示权重矩阵;  $b_i$  和  $b_c$  表示偏置量;  $\hat{c}_t$  为当前时间步的候选记忆状态;  $c_{t-1}$ 、 $c_t$  为当前时间步的记忆状态。

$$o_t = \sigma(W_o[h_{t-1}, r_t] + b_o) \quad (14)$$

$$h_t = o_t \cdot \tanh(c_t)$$

式中:  $h_t$  表示隐藏层输出值;  $o_t$  为输出门;  $W_o$  表示权重矩阵;  $b_o$  表示偏置量。

相较于传统的循环神经网络, LSTM 通过独特的门控设计,大幅降低了权重更新过程中梯度爆炸或梯度消失的风险,显著增强了模型的预测精度。具体网络结构如图 3 所示。

### 2.3 AM

在神经网络的应用中,注意力机制<sup>[18]</sup>本质上是一种资源优化策略,为了增强神经网络的处理效能,模型在处理输入数据时动态地调整其注意力权重,给予关键对象




图 3 LSTM 网络结构

Fig. 3 LSTM network structure diagram

更高的权重,对相对不重要的对象分配权重较少,从而突出重要信息并忽略不重要的信息。AM 的实施涉及计算各输入值的注意力权重并利用这些权重对输出值进行加权平均两个阶段,具体过程如图 4 所示。




图 4 Attention Mechanism 结构

Fig. 4 Attention Mechanism structure

### 2.4 多维特征时空融合网络模型

针对传统雷达 PRI 调制类型识别方法依赖人工特征设计、泛化能力弱,以及单一网络架构难以充分挖掘复杂时序模式等问题,本文提出一种多维特征时空融合的深度神经网络模型。有机融合 CNN、LSTM 和 AM 这 3 种网络的优势,协同提取 PRI 序列的局部空间特征与长程时间依赖关系,并通过动态加权策略突出判别性时刻,从而实现高精度、高鲁棒性的 PRI 调制类型识别。模型由 5 个核心层构成:输入层、CNN 层、LSTM 层、AM 层以及输出层,具体结构如图 5 所示。

卷积特征提取模块由两个卷积层和两个池化层级联构成。两级卷积层分别配置 32 个和 64 个  $3 \times 1$  卷积核,逐层捕获 PRI 序列的多尺度局部模式。每个卷积层后依次连接批归一化层、ReLU 非线性激活层、Dropout 层以及平均池化层,在增强非线性表达能力的同时显著提升模型的泛化能力。




图5 多维特征时空融合网络结构

Fig. 5 Multi dimensional feature spatiotemporal fusion network structure diagram

经 CNN 提取的高维特征序列被送入 LSTM 时序提取模块,该模块包含 64 个隐藏单元,用于捕获 PRI 序列中的长期依赖关系。随后,在 LSTM 输出端引入序列注意力机制,通过一个由两层全连接层构成的权重生成网络,为每个时间步计算注意力得分,经 Softmax 归一化后对 LSTM 输出加权求和,生成能够聚焦判别性脉冲时刻的上下文向量,经全连接层和 Softmax 函数输出 PRI 调制类型的预测概率分布,识别流程如图 6 所示。

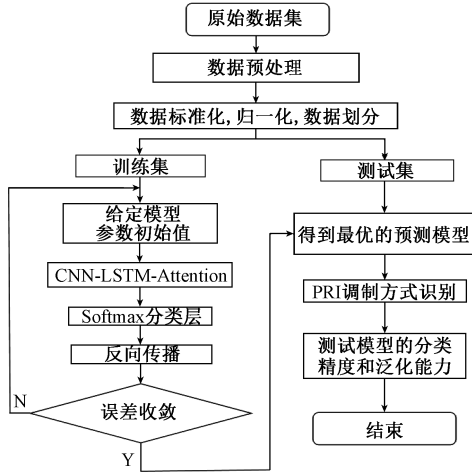


图6 雷达 PRI 调制识别流程

Fig. 6 Radar PRI modulation recognition flowchart

### 3 仿真与实验验证

#### 3.1 数据集生成

本文仿真了固定、抖动、参差、滑变和组变共 5 种典型的雷达 PRI 调制信号,参差信号的 PRI 个数不低于参差周期的两倍,组变信号的 PRI 个数大小于两倍的组个数,具体的仿真参数范围详见表 2,所有参数均在表 2 指定的范围内随机选取。

为模拟真实电磁对抗场景下的复杂干扰特性,本文采用梯度递增的干扰注入策略:脉冲丢失率与虚假脉冲率均以 5% 为步长从 0% 递增至 70%,其余关键参数在表 2 所定义的阈值区间内均匀随机采样,以充分覆盖信号特征的动态不确定性。基于蒙特卡洛仿真方法,针对

表 2 PRI 序列仿真参数

Table 2 PRI sequence simulation parameters

类型	PRI 范围/ $\mu\text{s}$	抖动范围/%	参差/脉组/滑变数/个	滑动步长/ $\mu\text{s}$	每组个数/个
固定	80~500	-	-	-	-
抖动	80~500	10~30	-	-	-
组变	80~500	-	3~7	-	5~10
参差	80~500	-	3~7	-	-
滑变	80~500	-	5~15	5~30	-

5 类 PRI 调制类型,在每个干扰强度下生成 5 000 组独立样本,最终构建包含 145 000 组样本的高置信度干扰数据集。该数据集通过可控的干扰强度梯度与多样化的随机参数组合,有效复现了实战环境中脉冲序列的统计特性,为模型的稳健性与鲁棒性评估提供了多维度、高覆盖的数据支撑。

#### 3.2 实验分析

##### 1) 模型性能分析

为评估所提算法在 5 类雷达脉冲重复间隔调制模式识别任务中的性能,开展了 PRI 调制模式的识别实验。实验采用无脉冲丢失、无虚假脉冲的理想样本,确保模型在纯净信号条件下充分学习调制特征。数据集按 0.7:0.15:0.15 的比例划分为训练集、验证集和测试集,所有序列长度统一设定为 180。模型训练采用 Adam 优化器,初始学习率设为 0.001,并结合余弦退火学习率调度策略与早停机机制以提升收敛效率,引入 Dropout、L2 正则化和标签平滑防止过拟合。小批量样本规模设置为 64,最大训练轮数为 200,每轮训练前对样本进行随机打乱处理,在独立测试集上评估模型性能。

图 7 展示了所提网络的训练过程。




图7 网络的训练过程

Fig. 7 Training process of the network

从图 7 中可以看出, 本文算法在前 20 轮次呈现指数级收敛趋势, 训练误差与验证误差同步显著下降, 迅速逼近问题最优解; 当迭代次数超过 20 轮次后, 误差曲线趋于平缓并最终稳定在预期的收敛水平, 充分验证了其在 PRI 调制识别任务中的有效性与可行性。

图 8 给出了 5 类典型 PRI 调制信号的混淆矩阵。实验结果显示, 各类调制模式均获得优异的识别性能, 在无干扰条件下, 系统整体平均识别准确率达 99.40%。仅存在极少量参差调制样本被误判为滑变调制, 该现象主要源于二者在时序结构上的局部相似性, 参差调制由多个固定的子周期交替组成, 其部分片段易与滑变调制的渐变特性混淆。总体而言, 所提方法在理想环境下展现出卓越的识别精度、稳定性与可靠性。




图 8 5 种典型的雷达 PRI 调制混淆矩阵

Fig. 8 Confusion matrix of five typical radar PRI modulation types

### 2) 脉序列长度对识别性能的影响

为探究输入序列长度  $N$  对模型识别性能的影响, 本文在脉冲丢失率为 30% 的干扰条件下开展实验。数据样本共 5 000 条, 原始脉冲序列长度为 400, 通过截取不同长度子序列进行测试。如图 9 所示, 识别准确率随序列长度增加而稳步提升。





图 9 脉序列长度对识别性能的影响

Fig. 9 Influence of pulse sequence length on recognition performance


当  $N=50$  时, 识别准确率显著受限, 主要归因于可用时序信息不足, 难以有效表征调制模式的结构特征; 当  $N$  增至 100 时, 准确率明显改善, 表明模型已能捕捉基本的周期或变化规律。然而, 当  $N>200$  后, 性能增益趋于饱和, 继续增加序列长度几乎不再带来识别精度的提升, 反而显著增加计算开销。该结果表明, 180~200 的序列长度已足以支撑高精度 PRI 调制识别, 兼顾效率与性能。

### 3) 模型稳健性验证

为评估所提方法在非理想环境下的适应性, 本文基于 3.1 节构建的干扰数据集, 采用交叉验证策略, 定量分析脉冲丢失与虚假脉冲对 PRI 调制识别性能的影响。图 10 分别展示了两类干扰下 5 类调制信号的识别准确率变化趋势, 揭示了不同调制类型对干扰的敏感性差异及其内在机理。



(a) 脉冲丢失对识别准确率的影响  
(a) Influence of pulse loss on recognition accuracy



(b) 虚假脉冲对识别准确率的影响  
(b) Influence of false pulse on recognition accuracy

图 10 非理想环境下调制类型识别结果

Fig. 10 Modulation type recognition results under non-ideal environment

实验结果表明, 随着干扰强度增加, 整体识别准确率呈下降趋势, 但两类干扰的影响程度存在显著差异。脉冲丢失对模型性能造成明显退化: 当丢失率从 0 升至 70% 时, 平均识别准确率由 99.40% 降至 70.93%。其根本原因在于脉冲缺失破坏了 PRI 序列的时域连续性与调制周期的完整性, 导致基于序列完整性的模式判断变得困难。

相比之下,虚假脉冲干扰对模型影响较小,即使虚假脉冲比例高达 70%,平均识别准确率仍维持在 96.13%,仅下降约 3.27 个百分点。这表明,所引入的序列注意力机制能够有效抑制异常脉冲的干扰,自适应聚焦于与真实调制模式相关的脉冲序列,从而保持对关键特征的鲁棒提取能力。

在不同调制类型中,抗干扰能力呈现出明显的结构性差异。固定调制凭借其严格的周期稳定性,在两种干扰下均保持极高的识别率,即使在 70% 脉冲丢失条件下,识别率仍保持 100%,展现出最优的鲁棒性。参差、抖动及滑变调制在中等干扰下仍能维持较高准确率,但在高丢失率下性能显著下降,主要是由于其线性变化趋势或随机波动特征易被大量丢失脉冲所掩盖,甚至引发相互误判。综上,所提模型不仅在理想条件下具备高精度识别能力,在复杂干扰场景下亦展现出优异的结构感知能力与鲁棒性,验证了其在实战电子战环境中的应用潜力。

#### 4) 不同模型对比分析

为全面评估模型的识别性能,本文在相同数据集和实验设置下,将本文网络与文献[16]提出的 SE-NET 网络、文献[14]提出的 GRU-Attention 网络、CNN 网络、CNN-LSTM 网络共 5 种网络进行对比实验。图 11 展示了各模型在 5 类雷达 PRI 调制信号上的识别准确率。

由图 11 可见,本文模型在所有调制类型识别中均表现最优,其次是 GRU-Attention、SE-NET、CNN-LSTM,而单一 CNN 模型表现最弱。随着干扰强度的增加,所以模型的识别准确率呈下降趋势,在高干扰强度下,相比其他网络,本文方法仍能保持较高的识别准确率,展现出更强的抗干扰能力。实验结果表明,通过融合局部特征提取、时序建模与注意力机制,本文模型能更有效地捕捉 PRI 序列的时空特征,显著提升在复杂干扰环境下的识别能力。

#### 5) 模型效率与实时性分析

为评估所提模型在工程部署中的适用性,本文从模型参数量、计算复杂度 FLOPs 及单样本推理时间 3 个关键维度,对比了不同网络的效率表现。实验在配备 NVIDIA RTX4070 GPU 的平台上进行,输入序列长度固定为 180,批大小设为 1,以模拟电子战系统中典型的单脉冲流实时推理场景。结果如表 3 所示。

表 3 不同网络的性能对比

Table 3 Performance comparison of different networks

类型	参数量	FLOPs	推理时间/ms
CNN-LSTM-Attention	653 814	$138.26 \times 10^6$	1.54
GRU-Attention	791 558	$141.84 \times 10^6$	1.68
SE-NET	4 095 813	$31.63 \times 10^6$	1.01
CNN-LSTM	201 605	$6.43 \times 10^6$	0.26
CNN	59 749	$1.21 \times 10^6$	0.21

由表 3 可知,所提 CNN-LSTM-Attention 模型在 FLOPs 与推理时间上略高于如 CNN-LSTM 与 CNN,这是因为引入了更复杂的时空融合结构与注意力机制以提升特征表达能力。虽然本文模型计算开销有所增加,但其在极端干扰下仍能保持较高的识别性能,而轻量模型在高干扰条件下性能急剧下降,难以满足实战的应用需求。在电子战中,识别准确性直接关系到威胁评估与对抗策略生成的可靠性,所提模型推理延迟仅为 1.54 ms,远低于典型雷达脉冲处理数十毫秒级的时间,该计算代价在可接受范围内,以适度的计算代价换取识别性能的大幅提升具有重要的实战价值。

此外,所提模型的总参数量为 653 814 个,远低于参数量为 4 095 813 的 SE-NET 网络,内存占用可控,具备良好的嵌入式部署潜力。未来可通过模型轻量化、硬件感知优化或异构计算加速等方式进一步提升其实时性,以适应更严苛的嵌入式部署场景。

#### 6) 实验数据验证

为进一步验证所提方法在真实信号环境下的有效性,本节采用实验室实采雷达数据进行测试。数据采集系统如图 12 所示,由中电科思仪科技股份有限公司生产

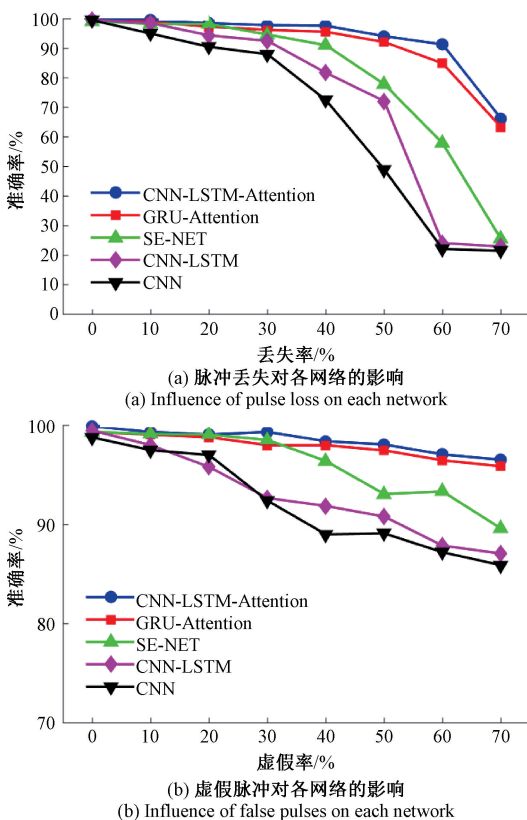


图 11 不同网络识别准确率对比

Fig. 11 Comparison of different network recognition accuracy

的 1466L-V 信号发生器、4071E 频谱分析仪及射频连接线构成。



图 12 实验数据采集系统

Fig. 12 Experimental data acquisition system

通过配置信号发生器参数,可生成多种 PRI 调制类型的雷达信号,信号经射频线传输后,由频谱分析仪完成数字化采集与记录。实采数据涵盖 4 类 PRI 调制模式:固定、参差、抖动与滑变。组变调制未纳入本次验证,主要受限于当前信号发生器尚不支持其真实波形生成。图 13 展示了所提模型在实采数据上的识别结果,所有类别识别率均接近 100%。该高精度表现主要得益于实验室环境的高信噪比特性:外部电磁干扰极小,且脉冲丢失率与虚假脉冲率均维持在极低水平。在此条件下,模型能够充分学习并精确区分各类 PRI 调制特征,验证了其在理想或近理想场景下的泛化能力与可靠性。




图 13 实采数据实验结果

Fig. 13 Experimental results of real data acquisition

## 4 结 论

针对现有雷达 PRI 调制类型识别方法在特征表达能力不足、抗干扰性能弱及依赖人工先验等方面存在的局限,本文结合 CNN 网络对空间特征的提取能力和

LSTM 网络对时序特征的捕捉能力,并引入注意力机制模块聚焦关键特征,实现雷达 PRI 调制类型的识别。仿真实验与实测数据验证表明,本文所提方法在复杂电磁干扰环境下仍能保持优异的识别准确率与鲁棒性,为雷达信号智能分选、威胁评估及电子对抗决策提供了有效技术支撑。

然而,研究仍存在一定局限性,一方面,当前模型主要基于仿真与受控实验室数据训练,与真实战场中信号仍存在一定偏差可能影响其泛化能力;另一方面,在极端干扰条件下,部分调制类型的识别性能仍有提升空间。未来工作将聚焦于多源异构数据的联合训练、轻量化网络设计以及对抗性训练策略的优化,以进一步提升模型的实用性与适应性。

## 参考文献

- [1] QU Q ZH, WEI SH J, WU Y, et al. ACSE networks and autocorrelation features for PRI modulation recognition[J]. IEEE Communications Letters, 2020, 24(8): 1729-1733.
- [2] 吴阳勇, 李文海, 吴忠德, 等. 一种高精度的雷达信号 PRI 调制类型识别的方法[J]. 电子测量技术, 2020, 43(13): 48-56.  
WU Y Y, LI W H, WU ZH D, et al. Method for identifying PRI modulation type of radar signal with high precision [J]. Electronic Measurement Technology, 2020, 43(13): 48-56.
- [3] 文秋月, 王志勇. 基于改进 EVM 的雷达 PRI 调制类型开集识别[J]. 现代雷达, 2024, 46(8): 22-28.  
WEN Q Y, WANG ZH Y. Open-set recognition of radar PRI modulation type based on improved EVM [J]. Modern Radar, 2024, 46(8): 22-28.
- [4] LESIEUR L, LE CAILLEC J M, KHENCHAF A, et al. An overview and classification of machine learning approaches for radar signal deinterleaving [J]. IEEE Access, 2025, 13: 28008-28028.
- [5] 李宝鹏, 彭志刚, 王艳军, 等. 基于 VST-FPGA 的雷达侦察与干扰系统设计[J]. 电子测量与仪器学报, 2020, 34(11): 181-187.  
LI B P, PENG ZH G, WANG Y J, et al. Design of radar reconnaissance and jamming system based on VST-FPGA[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(11): 181-187.
- [6] 蒋康, 张志勇, 张振源, 等. 基于随机有限集理论的雷达抗干扰目标跟踪方法[J]. 仪器仪表学报, 2025,



- 46(5): 299-311.
- JIANG K, ZHANG ZH Y, ZHANG ZH Y, et al. Random finite set theory-based method for radar anti-interference target tracking[J]. Chinese Journal of Scientific Instrument, 2025, 46(5): 299-311.
- [7] 薛磊, 黄中瑞, 刘照龙. 基于周期样本图重构的雷达 PRI 调制类型识别算法研究[J]. 信息对抗技术, 2023, 2(2): 75-89.
- XUE L, HUANG ZH R, LIU ZH L. Research on radar PRI modulation type recognition algorithm based on periodic sequence pattern reconstruction[J]. Information Countermeasure Technology, 2023, 2(2): 75-89.
- [8] WANG J, WANG H, XUE L, et al. Histogram-informed radar PRI modulation recognition with dual-branch network[J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(3): 7873-7885.
- [9] 常安琪, 牛栋, 乔宏乐, 等. 基于符号化序列的 PRI 调制类型识别[J]. 火控雷达技术, 2023, 52(4): 49-56.
- CHANG AN Q, NIU D, QIAO H L, et al. PRI modulation type identification based on symbolic sequences[J]. Fire Control Radar Technology, 2023, 52(4): 49-56.
- [10] 刘峻臣, 严波, 赵春雷, 等. 多特征联合的雷达脉冲重复间隔调制类型识别[J]. 现代防御技术, 2025, 53(1): 129-139.
- LIU J CH, YAN B, ZHAO CH L, et al. Modulation type recognition of radar PRI based on multi-feature combination[J]. Modern Defense Technology, 2025, 53(1): 129-139.
- [11] AZHDARI S M H, MAHMOODZADEH A, KHISHE M, et al. Pulse repetition interval modulation recognition using deep CNN evolved by extreme learning machines and IP-based BBO algorithm[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106415.
- [12] ZHOU D P, LU Y B, RUAN H, et al. Radar signal pulse train recognition with dual-branch LSTM-Transformer networks[J]. IEEE Access, 2025, 13: 166289-166300.
- [13] 黄中瑞, 唐波. 基于脉冲序列重构的雷达 PRI 调制类型智能识别算法研究[J]. 信号处理, 2024, 40(2): 263-271.
- HUANG ZH R, TANG B. Research on intelligent recognition algorithm for radar PRI modulation type based on pulse sequence reconstruction[J]. Journal of Signal Processing, 2024, 40(2): 263-271.
- [14] LI X Q, LIU ZH M, HUANG ZH T. Attention-based radar PRI modulation recognition with recurrent neural networks[J]. IEEE Access, 2020, 8: 57426-57436.
- [15] 孟磊, 曲卫, 马爽, 等. 基于 LSTM 的雷达脉冲重复间隔调制模式识别[J]. 现代雷达, 2021, 43(1): 50-57.
- MENG L, QU W, MA SH, et al. Radar PRI modulation pattern recognition method based on LSTM[J]. Modern Radar, 2021, 43(1): 50-57.
- [16] WEI SH J, QU Q ZH, WU Y, et al. PRI modulation recognition based on squeeze-and-excitation networks[J]. IEEE Communications Letters, 2020, 24(5): 1047-1051.
- [17] 付欣, 李晓童, 苟阳. 基于 CNN 的随钻声波仪器信号降噪方法研究[J]. 仪器仪表学报, 2025, 46(4): 270-282.
- FU X, LI X T, GOU Y. A CNN-based noise reduction method for acoustic logging while drill instrument signal[J]. Chinese Journal of Scientific Instrument, 2025, 46(4): 270-282.
- [18] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J]. 仪器仪表学报, 2023, 44(4): 19-27.
- WEI W, LYU Y, QI X Y, et al. State prediction method for power plant fans based on the CNN-LSTM-AM dynamic integrated model[J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.

## 作者简介



张世成, 2023 年于华北电力大学(保定)获得硕士学位, 现为中国电子科技集团公司第四十一研究所助理工程师, 主要研究方向为雷达信号处理、电子测试垂直领域大模型构建。

E-mail: 15069116193@163.com

**Zhang Shicheng** received his M. Sc. degree from North China Electric Power University in 2023. He is currently an assistant engineer at The 41st Research Institute of China Electronics Technology Group Corporation. His main research interests

include radar signal processing, and the construction of vertical-domain large models for electronic testing.



**周游**, 2022 年于中国石油大学(华东)获得博士学位, 现为中国电子科技集团公司第四十一研究所工程师, 主要研究方向为复杂电磁信号智能处理、电子测试垂直领域大模型构建。

E-mail: zhoyou@ei41.com

**Zhou You** received his Ph. D. degree from China University of Petroleum in 2022. He is currently an engineer at The 41st Research Institute of China Electronics Technology Group Corporation. His main research interests include intelligent processing of complex electromagnetic signals, and the construction of vertical-domain large models for electronic testing.



**年夫顺**, 1989 年于西安交通大学获得硕士学位, 现任中国电子科技集团首席科学家, 电子测试技术国家重点实验室学术委员会副主任, 主要研究方向为微波毫米波测量技术及仪器。

E-mail: nfwxmnk825@163.com

**Nian Fushun** received his M. Sc. degree from Xi'an Jiaotong University in 1989. He is currently the chief scientist of China Electronics Technology Group Corporation. He is the deputy director of the Academic Committee of the State Key Laboratory of Electronic Testing Technology. His main research interests

include microwave and millimeter wave measurement technology and instruments.



**王宏硕**, 2021 年于英国诺丁汉大学获得硕士学位, 现为中国电子科技集团公司第四十一研究所助理工程师, 主要研究方向为复杂电磁信号分离和电子测试领域大模型构建与开发。

E-mail: 18865363071@163.com

**Wang Hongshuo** received his M. Sc. Degree from the University of Nottingham in 2021. He is currently an assistant engineer at The 41st Research Institute of China Electronics Technology Group Corporation. His main research interests include Complex Electromagnetic signal separation and domain-specific LLMs development for electronic testing.



**韩顺利**(通信作者), 2010 年于浙江大学获得博士学位, 现为中国电子科技集团公司第四十一研究所研究员高级工程师, 主要研究方向为智能测试技术、量子测试技术。

E-mail: hsl@ei41.com

**Han Shunli** (Corresponding author) received his Ph. D. degree from Zhejiang University in 2010. He is currently a senior research engineer at The 41st Research Institute of China Electronics Technology Group Corporation. His main research interests include intelligent test technology and quantum test technology.