

引用格式:王军,薛磊,屠俑霖,等.基于时频域特征挖掘与自注意力机制融合的雷达PRI变化类型识别[J].信息对抗技术,2024,3(5):74-83.
[WANG Jun, XUE Lei, TU Yonglin. et al. Radar PRI variation mode recognition based on time-frequency domain feature mining and fusion via self-attention mechanism [J]. Information Countermeasure Technology, 2024, 3(5):74-83. (in Chinese)]

基于时频域特征挖掘与自注意力机制融合的 雷达PRI变化类型识别

王军¹,薛磊^{1*},屠俑霖¹,遇浩宁¹,姜建华²

(1. 国防科技大学电子对抗学院,安徽合肥 230037; 2. 中国电子科技集团公司第三十八研究所,安徽合肥,230088)

摘要 针对存在异常值时雷达辐射源脉冲重复间隔(pulse repetition interval, PRI)变化类型识别困难的问题,提出一种基于时频域特征挖掘与自注意力机制融合的雷达PRI变化类型识别方法。首先对PRI序列进行时序变化特征和小波特征分析,从时域和频域2个角度构建特征集;然后基于自注意力机制以数据驱动的方式学习时频特征之间的互补性,有效把握不同维度特征对识别效果的贡献,实现对不同维度特征的深度融合;最后基于全连接神经网络对融合后的特征进行模式分类,从而实现对PRI变化类型的识别。仿真结果表明,在不同异常值水平下,所提方法能够显著提高对6种典型PRI变化类型的识别准确率,而且识别效果要显著优于仅使用单一维度特征的方法。

关键词 时频域特征挖掘;小波变换;自注意力机制;神经网络;PRI变化类型识别

中图分类号 TN 957 文章编号 2097-163X(2024)05-0074-10

文献标志码 A DOI 10.12399/j.issn.2097-163x.2024.05.007

Radar PRI variation mode recognition based on time-frequency domain feature mining and fusion via self-attention mechanism

WANG Jun¹, XUE Lei^{1*}, TU Yonglin¹, YU Haoning¹, JIANG Jianhua²

(1. College of Electronic Engineering, National University of Defense Technology, Hefei 230037, China;
2. The 38th Research Institute of CETC, Hefei 230088, China)

Abstract Addressing the difficulty in recognising variation mode of the pulse repetition interval (PRI) of radar emitter when outliers are present, a method for recognising variation mode of PRI based on time-frequency domain feature mining and fusion via self-attention mechanism was proposed. Firstly, the time-varying characteristics and wavelet features of the PRI sequence were analyzed, and a feature set was constructed from both the time domain and frequency domain perspectives; then, based on the self-attention mechanism, it learned the complementarity between time-frequency features in a data-driven manner, effectively grasped the contribution of features from different dimensions to the recognition effect, and achieved deep fusion of features from different dimensions; finally, based on the fully connected neural network, the fused features were classified into patterns to achieve the recognition of PRI variation mode. Simulation results indicate that under different levels of

outliers, the proposed method can significantly improve the recognition accuracy for 6 typical PRI variation mode. Moreover, its recognition performance is substantially superior to methods that only utilize single-dimensional features.

Keywords time-frequency domain feature mining; wavelet transformation; self-attention mechanism; neural networks; recognition of PRI variation mode

0 引言

随着通信、导航和雷达系统技术体制的快速发展和应用,电磁环境中的信号密度越来越大^[1]。当多个雷达同时发射脉冲信号时,电子侦察设备会接收到多个辐射源目标交错的脉冲序列,接下来的任务便是对这些脉冲信号进行分选和聚类,从而识别出感兴趣的辐射源类型。这些交错的雷达脉冲信号往往由脉冲描述字(pulse description words,PDW)来表示。PDW包含脉冲宽度(pulse width,PW)、载频(carrier frequency,CF)、脉冲幅度(pulse amplitude,PA)、到达时间(time of arrival,TOA)、到达方向(direction of arrival,DOA)等统计特征^[2-3]。

通过大量的数据观测和分析验证,人们发现由TOA衍生出的脉冲重复间隔(pulses repetition interval,PRI)序列是一个相对可靠和稳定的特征。PRI是TOA序列的一阶差分,可以通过计算2个相邻脉冲TOA值之间的时间差得到。PRI表征了雷达发射的脉冲流的时间间隔特性,反映了TOA序列的内在规律,且往往与雷达辐射源的工作模式或者特定的任务需求关联密切^[3-4]。因此,识别PRI变化类型对辐射源及其工作模式的识别至关重要。起初,人们识别PRI变化类型通常使用PRI序列的分布直方图^[5-7],通过观察直方图的形态来实现不同PRI变化类型的识别。只要数据量足够大且PRI变化模式简单,该方法可以准确识别出PRI的类型。然而,随着雷达功能的多样化和反侦察抗干扰的需要,PRI变化模式变得相当复杂,再加上所侦收脉冲序列中异常值的影响,采用常规的直方图方法进行PRI变化类型的识别变得越来越困难,难以满足实际需求。为此,人们考虑结合特征工程和机器学习模型,设计鲁棒性分类识别算法实现对PRI变化类型的自动识别。本文从所处理的特征类别入手,将这些研究大致分为2类。

一是基于时域特征的PRI变化类型识别。

这类算法考虑从PRI序列变化的时序特点入手构建特征以实现对其识别。例如,文献[5,8]提出使用多层感知器(multi-layer perceptron,MLP)并提取一系列高维统计特征作为MLP的输入以进行PRI变化类型的识别。在此基础上,KAUPPI等^[9]提出使用2阶段的分层分类方案并利用PRI序列的时序变化特征来区分不同类型的PRI。文献[10]在PRI时间序列直方图的基础上,运用卷积方法来识别抖动PRI序列,但是无法适用于对其他PRI变化类型的识别。文献[11-13]将编码处理后的PRI序列输入卷积神经网络(convolution neural network,CNN)来对PRI进行识别;类似地,LIU等^[14-15]提出运用递归神经网络(recurrent neural network,RNN)对输入的PRI序列进行分类识别。这些基于时域特征的方法的缺点在于:异常值的介入会破坏原PRI变化的时序规律。当存在脉冲丢失和伪脉冲干扰时,这些时域特征会产生畸变,从而造成这些基于时序特征的识别方法失效。随着异常值的增多,这类方法的识别准确度下降较大。

二是基于变换域特征的PRI变化类型识别。其中最常见的是小波变换。小波变换是一种用于时间序列特征提取的经典方法,小波变换可以将信号分解成不同频率范围内的子信号,通过选择合适的小波基函数,可以使得不同频率范围内的子信号更加突出。相关研究发现,小波变换能够从频域角度,运用多通道滤波器组来提取PRI序列特征^[16-17]。典型的工作如文献[16]运用小波变换将PRI序列转化为三维时频图,再运用卷积神经网络和自注意力机制对变换后的三维时频特征图进行分类以实现PRI变化类型的识别。文献[17]基于小波变换构建PRI序列的频域特征集,以实现PRI变化类型的识别。另一种较为常见的变换方法是自相关变换。例如,文献[18]基于对PRI序列的自相关处理构建自相关系数特征集实现对PRI变化模式的识别。WEI等^[19-20]通过将PRI序列的自相关图送入深度神

神经网络来对 PRI 变化类型进行识别。还有一些其他的特征变换方法,如文献[21]利用 Walsh-Hadamard 变换对 PRI 序列进行处理,并实现对变化类型的识别。WANG 等^[22]通过将 PRI 序列的分布特性进行可视化以构建二维特征图,并送入卷积神经网络进行识别。这类方法的缺点在于:由于引入了特征变换过程,一方面丢失部分时域信息,使得算法未能够充分挖掘原 PRI 序列的时序性;另一方面增加了数据预处理步骤,导致这些方法的实用性较差。

为解决上述问题,提高在复杂电磁环境下对 PRI 变化类型识别的鲁棒性和准确性,本文考虑从多个维度提取 PRI 序列特征并进行深度融合以实现 PRI 序列的鲁棒性表示,进而提高对 PRI 变化类型的识别效果。

1 典型 PRI 变化类型

雷达辐射源脉冲序列中的 PRI 特征^[4,6]定

义为:

$$P(j) = t(j+1) - t(j) \quad (1)$$

式中, $j = 1, 2, \dots, L-1, L$ 表示该时间段内接收机检测到的脉冲个数; $t(j)$ 表示第 j 个雷达脉冲的到达时间; $P(j)$ 表示第 j 个 PRI 值的大小。雷达辐射源常常会根据其所执行的功能任务灵活改变其 PRI 的变化类型,常见的类型有:PRI 固定、PRI 抖动、PRI 驻留与转换、PRI 参差、PRI 滑变和 PRI 正弦等^[6],这 6 种常见的 PRI 变化类型仿真示例如图 1 所示。其中,PRI 固定通常出现在搜索与跟踪雷达中;PRI 抖动通常用作电子防御,以尽量减少干扰的影响;PRI 驻留与转换通常用在脉冲多普勒雷达中,以解决测速或测距模糊问题;PRI 参差通常用在动目标指示雷达中以消除盲速;PRI 滑变常用于在仰角扫描期间的恒定高度覆盖和防止雷达目标遮蔽;PRI 正弦序列像正弦函数一样周期性变化以进一步提升雷达的测速或测距性能。

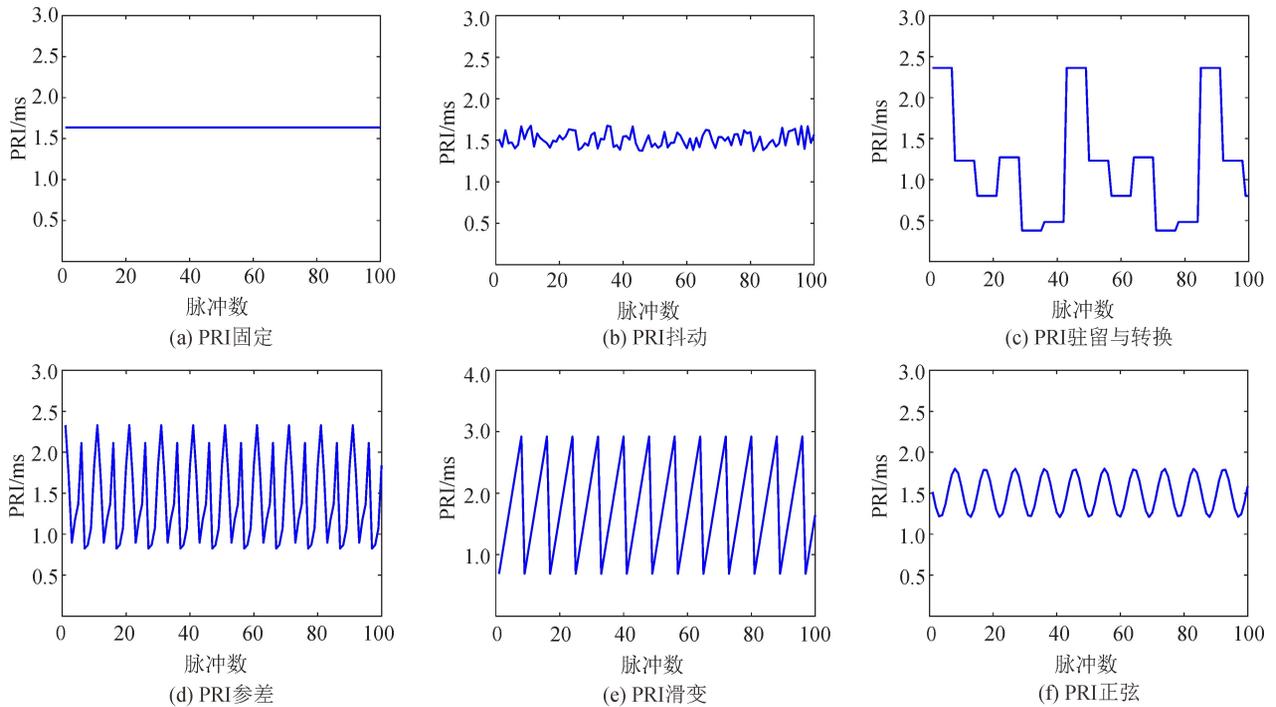


图 1 6 种 PRI 变化类型仿真示例

Fig. 1 Illustration of 6 types of PRI variation mode

2 本文对 PRI 变化类型识别方法的设计与实现

2.1 总体框架

本文方法总体框架结构如图 2 所示,共包含 PRI 序列输入、PRI 时频域特征挖掘、时频特征集

生成、自注意力机制融合和全连接层分类等步骤。具体而言,首先从时域和频域 2 个维度对输入 PRI 序列进行处理和特征提取,以构建特征集。多维度的特征分析能够从不同角度对 PRI 的内在变化信息进行挖掘,从而提高识别准确度;随后构建自注意力网络,结合自注意力机制

强大的数据表征能力^[23],以数据驱动的方法来学习时域和频域特征之间的互补性并有效把握不同域特征对识别效果的贡献,从而实现对不同维度特

征的深度融合;最后通过全连接网络输出PRI变化类型的识别结果。下文重点对PRI序列时频特征挖掘、基于自注意力机制的特征融合进行分析。

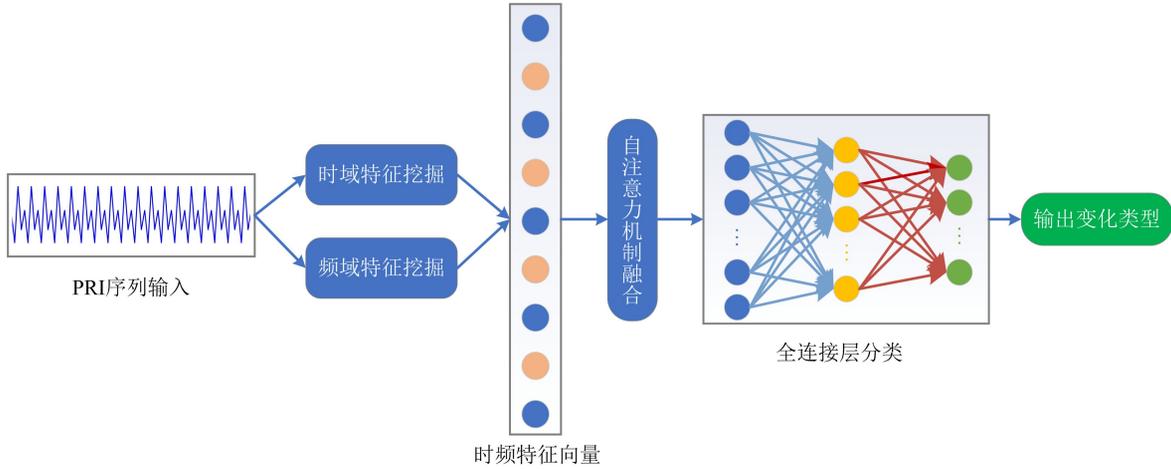


图2 总体框架结构图

Fig. 2 Diagram of overall framework structure

2.2 PRI序列时频域特征挖掘

2.2.1 基于统计分析的PRI序列时域特征挖掘

本文以PRI序列经典直方图算法^[6-7]为基础,通过统计学分析来挖掘PRI序列的时序变化特征。结合已有文献的研究^[8-9],本文设计统计特征 $f_1 \sim f_5$ 来描述PRI序列的时序变化特征。

第1个特征 f_1 定义为PRI序列直方图的次峰值与峰值之比:

$$f_1 = \frac{n'_{\max}}{n_{\max}} \quad (2)$$

式中, n_{\max} 表示PRI序列直方图中的峰值, n'_{\max} 表示PRI序列直方图的次峰值。 f_1 能够较好分辨出固定PRI序列,因为在固定PRI序列的直方图中,只有一个典型峰值,因此其特征 f_1 趋近于0,而其他变化类型不具备此特点。

第2个特征 f_2 定义为:

$$f_2 = \max(u_d), d=2,3,\dots,D_{\max} \quad (3)$$

式中, $u_d = n_d^{\max}/(N-d-1)$; n_d^{\max} 为第 d 阶的PRI序列直方图的峰值; N 表示PRI序列所包含的脉冲个数; D_{\max} 为经验值,表示常见周期性PRI序列中的PRI典型状态值的个数极值,本文设置为10。 f_2 能够较好判别出周期性与非周期性的PRI序列。

第3个特征 f_3 定义为:

$$f_3 = \frac{1}{N-2} \cdot \sum_{k=1}^{N-2} |s_k| \quad (4)$$

式中,序列 s_k 的计算方法如下:

$$s = \text{sgn}(z) \quad (5)$$

$$\text{sgn}(z_n) = \begin{cases} -1, & z_n < -\epsilon \\ 0, & |z_n| \leq \epsilon \\ 1, & z_n > \epsilon \end{cases} \quad (6)$$

$$z_k = P_{k+1} - P_k, k=1,2,\dots,N-2 \quad (7)$$

$$P_k = t_{k+1} - t_k, k=1,2,\dots,N-1 \quad (8)$$

式中, t_k 为第 k 个脉冲的到达时间, ϵ 为判定门限值。 f_3 能够表示PRI序列变化的稳定性。

第4个特征 f_4 的定义为:

$$f_4 = \frac{1}{N-2} \cdot \left| \sum_{k=1}^{N-2} s_k \right| \quad (9)$$

f_4 能够有效判断出PRI序列变化的单调性。

第5个特征 f_5 的定义为:

$$f_5 = \sum_{k=1}^{N-3} |\text{sgn}(r_k)| / (N-3) \quad (10)$$

$$r_k = s_{k+1} - s_k, k=1,2,\dots,N-3 \quad (11)$$

基于所设计的 $f_1 \sim f_5$,可以为每个PRI序列构建一个特征向量 $f_t = [f_1, f_2, f_3, f_4, f_5]^T$ 来综合表征PRI序列的时序特征。

2.2.2 基于小波变换的PRI序列频域特征挖掘

由于小波变换的多分辨率分析的特点,它可以适应不同PRI变化类型的处理需求。通过对小波变换后的子信号进行处理,可以提取出与PRI相关的频域特征,从而能够有效区分不同

PRI变化类型。本文利用 Haar 小波对 PRI 序列进行特征分析。Haar 小波定义为：

$$\Psi(t) = \begin{cases} 1, & t \in [0, 1/2) \\ -1, & t \in [1/2, 1) \\ 0, & t \notin [0, 1) \end{cases} \quad (12)$$

通过伸缩和平移运算可以得到小波变换中的整套基函数：

$$\Psi_{m,n}(t) = 2^{-m/2} \Psi(2^{-m}t - n) \quad (13)$$

式中, m 为尺度因子, n 为平移因子, $m, n \in \mathbb{Z}$; $2^{-m/2}$ 为归一化因子。考虑到 PRI 序列为离散时间序列, 则在离散情况下, 上述小波变换可以表示为：

$$g_{j,k}(n) = 2^{-j/2} g(2^{-j}n - k) \quad (14)$$

式中, $k, n \in \mathbb{Z}, j \in \mathbb{N}$ 。对于 PRI 序列 $P_n, n = 1, 2, \dots, N-1$, 它在尺度 2^j 上小波分解的细节系数可以表示为：

$$c(j, k) = \sum_n P_n g_{j,k}(n) \quad (15)$$

从 Z_n 的小波分解中提取的第 1 类特征为：

$$\mathbf{f}_1^w = [E_1, E_2, \dots, E_L]^T \quad (16)$$

式中, L 为有效分解层数个数, 综合考虑所提取特征的精度和计算的时效性, 本文设置 $L = 3$; E_i 为 Z_n 小波分解的第 i 层 (或第 i 个子带) 的能量平方和, 即：

$$E_i = \sum_j \|c^i(j)\|^2 = \sum_j (c^i(j))^2 \quad (17)$$

式中, $c^i(j)$ 表示第 i 层分解的第 j 个细节系数, $j = 1, 2, \dots, M/2^i$; M 为进行小波分解过程时的经验性参数, 通常设置为 2 的倍数, 以便于实现快速小波分解, 本文设置 $M = 128$ 。

第 2 类特征是第一个子带小波系数中值的幅值大小：

$$\mathbf{f}_2^w = |\text{median}\{c^1(j)\}|, j = 1, 2, \dots, M/2 \quad (18)$$

第 3 类特征定义如下：

$$\mathbf{f}_3^w = [K(c^1), K(c^2), K(c^3), N(c^1), N(c^2), N(c^3)]^T \quad (19)$$

式中, $K(c^i) (i = 1, 2, 3)$ 表示第 i 个子带小波系数的样本峭度：

$$K(c^i) = \frac{\frac{1}{M/2^i} \sum_{j=1}^{M/2^i} (c^i(j) - u_c^i)^4}{\left(\frac{1}{M/2^i} \sum_{j=1}^{M/2^i} (c^i(j) - u_c^i)^2\right)^2} \quad (20)$$

式中, c^i 为第 i 个子带的小波系数, u_c^i 为第 i 个子带的小波系数的样本均值。 $N(c^i)$ 为第 i 个子带小波系数的局部极值的个数。最后, 将 3 类小波变换特征 $\mathbf{f}_1^w, \mathbf{f}_2^w, \mathbf{f}_3^w$ 进行串联, 得到 PRI 序列的频域特征：

$$\mathbf{f}_p = [\mathbf{f}_1^w, \mathbf{f}_2^w, \mathbf{f}_3^w]^T \quad (21)$$

2.3 基于自注意力机制的时频特征融合

对提取的时频域特征进一步融合可以提高对 PRI 变化类型的识别效果。自注意力机制是一种基于有监督学习的特征处理方法, 可以高效地迁移到各种场景中以实现不同模态特征的深度融合^[2,16]。本文借助 Transformer 网络^[23]中自注意力机制对时频特征进行融合, 以数据驱动的方式有效把握不同特征的重要程度, 并充分挖掘这些特征之间的互补性, 从而提高 PRI 识别的准确度。为此, 本文构建了一个基于多头自注意力机制的 PRI 序列时频特征融合框架, 实现了时频处理后的 2 类特征的深度融合, 其原理如图 3 所示。

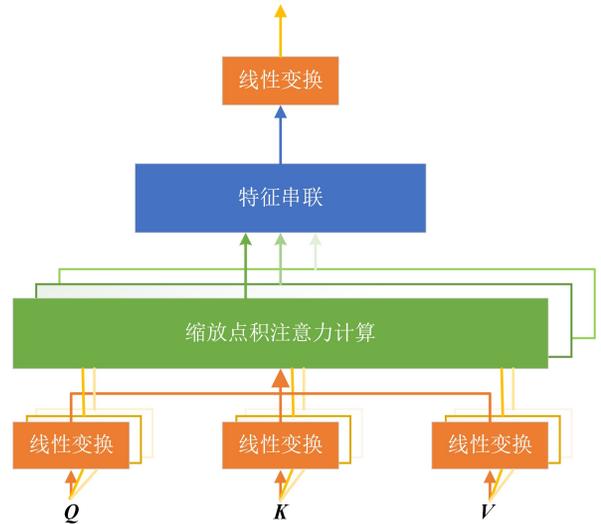


图 3 多头自注意力机制结构图

Fig. 3 Structure diagram of multi-head self-attention mechanism

为了充分挖掘 PRI 序列的变化特性, 并进一步丰富特征集构成, 对原 PRI 序列及其一阶差分序列 DPRI 分别从时域、频域 2 个维度提取特征并进行串联构建混合特征向量 $\mathbf{f}_{\text{hybrid}} = [\mathbf{f}_t, \mathbf{f}_p, \mathbf{f}_t^d, \mathbf{f}_p^d]^T$, 其中 $\mathbf{f}_t, \mathbf{f}_p$ 分别表示 PRI 序列的时域和频域特征; $\mathbf{f}_t^d, \mathbf{f}_p^d$ 分别表示 DPRI 序列的时域和频域特征。在多头自注意力机制中, 首先借助可学习权重矩阵 $\mathbf{W}_q, \mathbf{W}_k$ 和 \mathbf{W}_v , 将特征

f_{hybrid} 线性映射到查询空间 \mathbf{Q} , 键空间 \mathbf{K} 以及值空间 \mathbf{V} 中, 这个过程可以表示为:

$$\mathbf{Q} = f_{\text{hybrid}} \mathbf{W}_q = [q_1, q_2, \dots, q_\mu]^T \quad (22)$$

$$\mathbf{K} = f_{\text{hybrid}} \mathbf{W}_k = [k_1, k_2, \dots, k_\mu]^T \quad (23)$$

$$\mathbf{V} = f_{\text{hybrid}} \mathbf{W}_v = [v_1, v_2, \dots, v_o]^T \quad (24)$$

式中, μ, o 均为经过线性映射后的特征维度大小。多头自注意力机制要求矩阵(向量) \mathbf{Q} 和 \mathbf{K} 的特征维度必须一致, 以便进行不同特征间注意力分数的计算^[23]; 矩阵(向量) \mathbf{V} 的特征维度可以与 \mathbf{Q} , \mathbf{K} 的维度一致, 也可以不一致, 但必须能够被注意力头的个数所整除。

随后使用缩放点积和 Softmax 函数来计算注意力权重值, 并通过加权方法获得单通道特征输出 \mathbf{Y}_i , 即对于每个通道有:

$$\mathbf{Y}_i = f_{\text{sm}} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{D_{\mathbf{K}}}} \right) \cdot \mathbf{V} \quad (25)$$

式中, $f_{\text{sm}}(\cdot)$ 为 Softmax 归一化函数; $D_{\mathbf{K}}$ 为输入向量 \mathbf{K} 的维数; \mathbf{K}^T 为 \mathbf{K} 的转置, $\mathbf{Q}\mathbf{K}^T/\sqrt{D_{\mathbf{K}}}$ 为 \mathbf{Q} 和 \mathbf{K} 之间的缩放点积运算, 以求取经过映射后的不同特征空间的关联度大小, 也即注意力权重。将多个通道的输出结果拼接起来, 便可以得到最终的时频特征融合结果:

$$\mathbf{Y} = f_{\text{con}}(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_\lambda) \quad (26)$$

式中, f_{con} 是特征级联操作。在本文中参数 μ, o 均设置为 256, λ 设置为 4。最后, 本文采用一个 3 层的全连接层作为分类层对多头自注意力机制模块输出的融合特征进行识别, 以判断 PRI 序列的变化类型。本文采用随机梯度下降法进行整个网络模型(多头自注意力机制特征融合层+全连接分类层)的训练, 训练过程以及所用的仿真数据将会在实验部分进行详细介绍。识别过程如算法 1 所示。

算法 1 基于时频域特征挖掘与自注意力机制融合的雷达 PRI 序列变化类型识别

输入: 雷达辐射源脉冲序列的到达时间 $\{t(j)\}_{j=1}^L$;

输出: PRI 变化类型。

1. 根据式(1)对脉冲序列的到达时间作一阶差分处理得到 PRI 序列 $[P_1, P_2, \dots, P_{L-1}]$;
2. 根据式(2)~(11)对 PRI 序列进行处理, 得到 PRI 序列的时域特征 f_t ;
3. 根据式(12)~(21)对 PRI 序列进行处理, 得到 PRI 序列的频域特征 f_p ;
4. 对 PRI 序列作一阶差分处理得到 DPRI 序列;
5. 重复步骤 2~3 得到 DPRI 序列的时、频域特征 f_t^d

和 f_p^d ;

6. 根据式(22)~(26)对不同特征进行融合;

7. 运用全连接网络模型对融合后的特征进行判别, 输出 PRI 变化类型;

8. 结束。

3 实验与分析

3.1 实验条件和环境

1) 不同变化类型的 PRI 序列仿真。在实验中共仿真了 6 种变化类型的 PRI 序列, 用于特征提取、网络训练和性能测试。6 种 PRI 变化类型的详细参数设置见表 1 所列。每类 PRI 序列在仿真中均随机加入一定比例的异常值。

表 1 6 种变化类型 PRI 的参数设置

Tab. 1 Parameter settings of 6 types of PRI variation mode

PRI 变化类型	参数类型	参数取值范围
固定	平均值/ms	0.1~3.0
	平均值/ms	0.1~3.0
抖动	抖动范围	平均值的 $\pm 3\% \sim \pm 30\%$
	平均值/ms	0.1~3.0
	振幅	平均值的 10%~50%
正弦	频率/Hz	3~12
	相位	0~2 π
	变化步长/ μs	30~70
	渐变	每个渐变周期内的脉冲数/个
每个周期的初始值/ms		0.1~0.5
参差	参差值数/个	3~10
	参差值大小/ms	0.1~3.0
驻留与转换	取值范围/ms	0.1~3.0
	每个周期内信号转换数/次	3~10
	转换之前持续数/次	5~20

2) 异常值设置。仿真时考虑了 3 种类型的异常值, 包括丢失脉冲、干扰脉冲和测量误差。以上异常值均随机出现在每个仿真样本中, 3 类异常值出现的概率均为随机设定。其中丢失脉冲情况下的异常值是指在信号观测过程中由于脉冲丢失导致的异常 PRI, 其数量占据整个 PRI 序列长度的比例表示为脉冲丢失率, 本文设定在 $[0, 0.7]$ 之间。干扰脉冲是指在信号观测过程中

接收到的来自其他干扰辐射源的脉冲,与需要识别的脉冲 PRI 序列类型不相关;在一定的脉冲丢失率下,由于随机出现的干扰脉冲导致的异常 PRI 数量占据整个 PRI 序列长度的比例,表示为脉冲干扰率,本文设定在 $[0, 0.7]$ 之间。测量误差是指由于信号接受设备测量结果的不精确性导致的观测 PRI 值与雷达的真实 PRI 值的偏离程度,本文设定在 $[0, 0.1]$ 之间。

3) 训练集和测试集。在网络训练阶段,每种 PRI 变化类型共仿真 20 000 个序列样本,每个样本的长度介于 300~500 之间,共生成 120 000 个 PRI 序列样本用于训练网络模型,每个 PRI 序列都加入了随机比例的异常值。在测试阶段,分别在不同的脉冲丢失率和脉冲干扰率下进行 PRI 仿真测试以验证所提模型的鲁棒性,其中每个异常值水平下分别仿真 1 000 条 PRI 序列。

4) 评估指标。本文使用识别准确率和 F_1 分数来评估模型的性能^[16]。识别准确率定义为正确分类的样本数与样本总数之比。 F_1 分数是机器学习中用来衡量分类模型精度的指标,它考虑了分类模型的准确率和召回率。 F_1 分数定义为:

$$F_1 = 2 \cdot \frac{P_{\text{precision}} \cdot R_{\text{recall}}}{P_{\text{precision}} + R_{\text{recall}}} \quad (27)$$

式中,准确率和召回率分别如下:

$$P_{\text{precision}} = \frac{\varphi_{\text{TP}}}{\varphi_{\text{TP}} + \varphi_{\text{FP}}}, R_{\text{recall}} = \frac{\varphi_{\text{TP}}}{\varphi_{\text{TP}} + \varphi_{\text{FN}}} \quad (28)$$

式中, φ_{TP} 为真阳性率, φ_{FP} 为假阳性率, φ_{FN} 为假阴性率。

3.2 结果分析

3.2.1 时频域特征对识别 PRI 变化类型的有效性分析

为了验证所提取时频特征对识别 PRI 变化类型的有效性,本节进行了特征消融实验。将提取的时域和频域特征分别输入神经网络进行模型训练,并记录了模型在不同特征下的收敛情况。比较结果如图 4 所示,图中展示的 4 项实验结果均是在相同的环境下,基于相同的梯度优化算法和网络架构进行的。可以看出,在单独使用时域和频域特征的情况下,网络模型的训练收敛情况较差,而基于自注意力机制进行深度融合后的特征能够显著提升网络模型的收敛速度,并提高识别准确率。特征消融实验进一步说明了本文所提出的时频特征融合方法对识别 PRI 变化

类型的有效性。

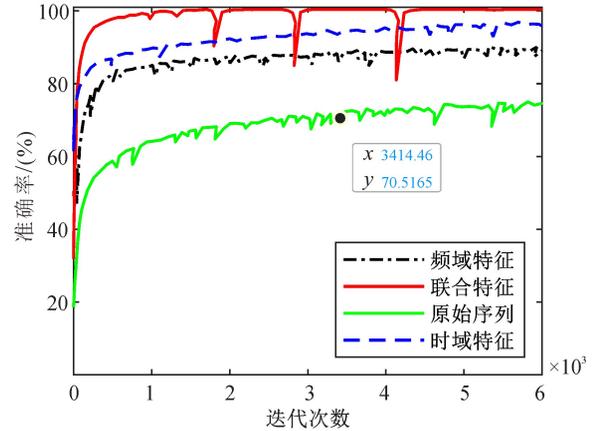


图 4 不同特征下的网络模型收敛情况对比
Fig. 4 Comparison of convergence performance with different features

3.2.2 不同异常值水平下的识别准确率

为研究识别 PRI 变化类型的鲁棒性,本文在不同异常值水平下进行了识别性能测试。图 5 显示了 6 个类别的 PRI 在不同异常值水平下的综合识别准确率。每条曲线表示在相同的脉冲丢失率下,识别准确率随脉冲干扰率增加而变化的情况。可以看出,当脉冲丢失率低于 20% 时,即使在 70% 干扰脉冲的极端条件下,识别准确率仍然高于 95%,而且识别准确率下降较慢。当脉冲丢失率达到 70% 时,随着脉冲干扰率的增加,识别准确率下降很快。分析性能下降的原因是,当脉冲流中的干扰脉冲和丢失脉冲数量过多时,时频特征变得不稳定,使其对不同变化类型的 PRI 进行有效区分的难度增加。

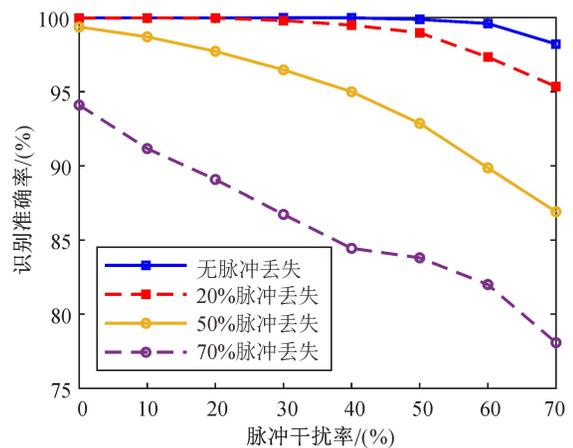
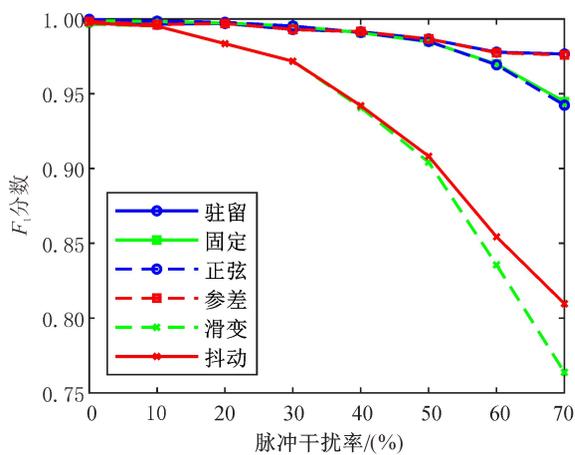


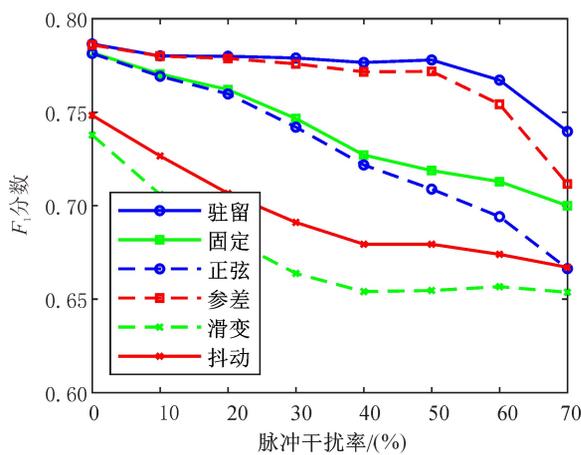
图 5 不同脉冲丢失率和干扰率情况下的算法识别性能曲线
Fig. 5 Recognition performance under different lost pulse ratios and spurious pulse ratios

3.2.3 对不同变化类型的 PRI 识别性能

为进一步研究不同 PRI 变化类型的识别性能,本文在不同异常值水平下对不同 PRI 模式进行独立识别测试,发现识别不同变化类型 PRI 的性能表现对异常值水平有着不同的反应。图 6 (a)和图 6(b)分别分析了当脉冲丢失率为 30%和 70%时,识别不同 PRI 的 F_1 分数随着脉冲干扰率的增加而变化的情况。可以看出,本文方法识别 PRI 参差和 PRI 驻留的 F_1 分数受干扰脉冲的影响较小,而识别 PRI 正弦和 PRI 固定的 F_1 分数受干扰脉冲的影响较大,识别 PRI 抖动和 PRI 滑变的 F_1 分数受干扰脉冲的影响最大。综合来看,随着干扰脉冲的增加,本文方法识别 PRI 驻留和 PRI 参差的性能表现优于识别 PRI 固定和 PRI 正弦的性能表现,优于识别 PRI 抖动和 PRI 滑变的性能表现。



(a) 脉冲丢失率为30%时的识别性能



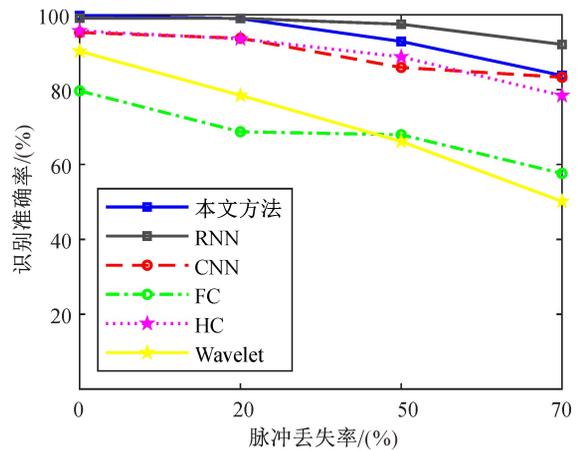
(b) 脉冲丢失率为70%时的识别性能

图 6 对不同变化类型 PRI 的识别性能分析

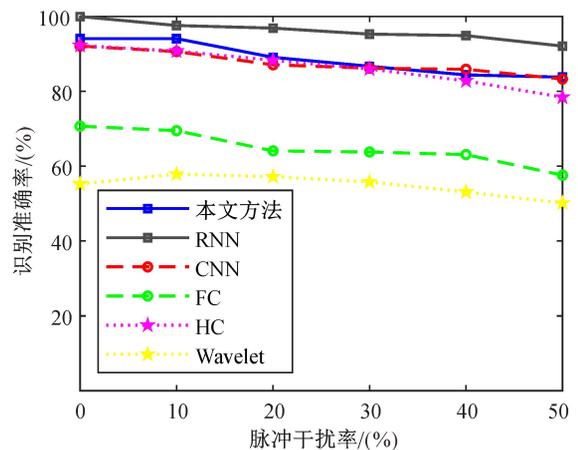
Fig. 6 Analysis of recognition performance for different PRI variation mode

3.2.4 不同特征识别性能比较

为了进一步验证本文方法的有效性,将本文所提方法的识别性能与 RNN^[4]、FC^[5]、HC^[9]、Wavelet^[17]和 CNN^[22]等基准方法进行了比较。其中,RNN、CNN 和 FC 是基于深度学习的识别方法;HC 方法是基于本文时域统计特征的识别方法;而 Wavelet 是基于本文小波特征的识别方法。不同方法的识别性能对比如图 7 所示,不同方法的特征对比情况见表 2 所列。为了确保实验的公平性,实验中的其他测试条件均相同。



(a) 脉冲干扰率为50%时的识别性能对比



(b) 脉冲丢失率为70%时的识别性能对比

图 7 与其他方法的识别性能对比

Fig. 7 Comparison of recognition performance with other methods

图 7(a)显示了当脉冲干扰率为 50%时,随着脉冲丢失率的增加,不同特征对应的识别准确率变化情况;图 7(b)显示了当脉冲丢失率 70%时,随着脉冲干扰率的增加,不同方法的识别准确率变化情况。可以看出,随着脉冲丢失率或脉冲干扰率的增加,本文提出的方法可以获得比 CNN、FC、HC、Wavelet 等方法更高的识别准确率。这

充分说明了本文时频特征融合模型的有效性。单从对 PRI 变化类型识别准确率而言, RNN 方法的识别性能略高于本文提出的方法, 但 RNN 模型中对于 PRI 序列的 One-hot 特征编码过程大大增加了其输入特征维度; 与之相比, 本文方法可以在输入特征维数远小于 RNN 模型的情况下获得接近于 RNN 方法的识别准确率, 充分表明了本文方法的优越性。

表 2 不同识别方法输入特征情况对比

Tab. 2 Comparison of input features for different recognition methods

方法	输入特征类型	输入特征维度
RNN ^[4]	PRI 序列 One-hot 编码特征	300×10 000
FC ^[5]	PRI 序列累积变化曲线	1×64
HC ^[9]	PRI 序列统计特征	1×10
Wavelet ^[17]	PRI 序列小波特征	1×16
CNN ^[22]	PRI 序列分布特征图	224×224
本文所提方法	PRI 序列时频特征集	1×30

4 结束语

雷达 PRI 具有丰富的变化类型, 而且常常与雷达工作模式关联密切, 分析雷达 PRI 变化规律并识别其类型是电子对抗领域近年来研究热点之一。本文提出了一种基于时频域特征挖掘与自注意力机制融合的方法, 以实现在较多异常值环境下对 PRI 变化类型的准确识别。为此, 从 PRI 序列及其一阶差分序列中分别提取了 5 个时域特征和 3 类频域特征, 并构建自注意力机制网络进行时频特征的深度融合, 最后经过全连接层实现对不同 PRI 序列的模式分类。实验仿真结果表明, 本文时频域特征深度融合的识别效果显著优于单一使用时域或频域特征的方法。在不同异常值水平下, 所提方法能够对不同变化类型的 PRI 取得较高的识别正确率, 而且算法性能优于目前主流方法。

参 考 文 献

- [1] 刘梅, 杨威, 高勋章, 等. 基于多 PRI 脉压回波的单通道雷达干扰分离方法[J]. 信息对抗技术, 2024, 3(1): 70-80.
LIU Mei, YANG Wei, GAO Xunzhang, et al. Interference separation method of single-channel radar based on multi-PRI pulse compression echoes[J]. Information Countermeasure Technology, 2024, 3(1): 70-80. (in Chinese)
- [2] WEI S J, QU Q Z, ZENG X F, et al. Self-attention Bi-LSTM networks for radar signal modulation recognition[J]. IEEE Transactions on Microwave Theory and Techniques, 2021, 69(11): 5160-5172.
- [3] 袁硕, 拓世英, 尚文秀, 等. 电子侦察脉冲列中重频信息提取与应用综述[J]. 信息对抗技术, 2023, 2(6), 17-28.
YUAN Shuo, TUO Shiyong, SHANG Wenxiu, et al. Extraction and application of pulse repetition frequency information in radar pulse train: a survey[J]. Information Countermeasure Technology, 2023, 2(6): 17-28. (in Chinese)
- [4] LI X L, LIU Z M, HUANG Z T, et al. Attention-based radar PRI modulation recognition with recurrent neural networks[J]. IEEE Access, 2020, 8: 57426-57436.
- [5] NOONE G P. A neural approach to automatic pulse repetition interval modulation recognition[C]//Proceedings of 1999 Information, Decision and Control, Data and Information Fusion Symposium, Signal Processing and Communications Symposium and Decision and Control Symposium. [S. l.]: IEEE, 1999: 213-218.
- [6] 王海, 唐波, 黄中瑞, 等. 雷达辐射源分析[M]. 北京: 科学出版社, 2022.
WANG Hai, TANG Bo, HUANG Zhongrui, et al. Analysis of radar emitter[M]. Beijing: Science Press, 2022. (in Chinese)
- [7] NISHIGUCHI K, KOBAYASHI M. Improved algorithm for estimating pulse repetition intervals[J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36(2): 407-421.
- [8] KAUPPI J-P, MARTIKAINEN K. An efficient set of features for pulse repetition interval modulation recognition[C]//Proceedings of 2007 IET International Conference on Radar Systems. [S. l.]: IET, 2007: 1-5.
- [9] 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.
- [10] BAGHERI M, SEDAAGHI M H. A new method for detecting jittered PRI in histogram-based methods[J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2018, 26(3): 1214-1224.
- [11] SUN J, XU G L, REN W J, et al. Radar emitter

- classification based on unidimensional convolutional neural network[J]. IET Radar, Sonar & Navigation, 2018,12(8):862-867.
- [12] 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.
- [13] DADGARNIA A, SADEGHI M T. Automatic recognition of pulse repetition interval modulation using temporal convolutional network[J]. IET Signal Processing, 2021,15(9):633-648.
- [14] LIU Z M. Recognition of multifunction radars via hierarchically mining and exploiting pulse group patterns[J]. IEEE Transactions on Aerospace and Electronic Systems, 2020,56(6):4659-4672.
- [15] LI X Q, LIU Z M, HUANG Z T, et al. Radar emitter classification with attention-based multi-RNNs[J]. IEEE Communications Letters, 2020,24(9):2000-2004.
- [16] SHARMA P, SARMA K K. Attention driven CWT-deep learning approach for discrimination of radar PRI modulation [J]. Physical Communication, 2024(2):102237.
- [17] GENCOL K, AT N, KARA A. A wavelet-based feature set for recognizing pulse repetition interval modulation patterns[J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2016,24(4):3078-3090.
- [18] SHI Z Y, WU H, SHEN W D, et al. Feature extraction for complicated radar PRI modulation modes based on auto-correlation function[C]//Proceedings of 2016 IEEE Advanced Information Management, Communication, Electronic and Automation Control Conference. [S. l.]:IEEE, 2016:1617-1620.
- [19] WEI S J, QU Q Z, WU Y, et al. PRI modulation recognition based on squeeze-and-excitation networks [J]. IEEE Communications Letters, 2020,24(5):1047-1051.
- [20] QU Q Z, WEI S J, WU Y, et al. ACSE networks and autocorrelation features for PRI modulation recognition [J]. IEEE Communications Letters, 2020,24(8):1729-1733.
- [21] GHANI K A, SHA' AMERI A Z, DIMYATI K, et al. Pulse repetition interval analysis using decimated walsh-hadamard transform[C]//Proceedings of 2017 IEEE Radar Conference. [S. l.]:IEEE, 2017:58-63.
- [22] WANG J, WANG H, TANG B, et al. Visualization and classification of radar emitter pulse sequences based on 2D feature map[J]. Physical Communication, 2023,61(12):102168.
- [23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31th Conference on Neural Information Processing Systems. [S. l. :s. n.], 2017:1-11.

作者简介

王 军

男,1995年生,博士研究生,讲师,研究方向为机器学习与电子侦察数据智能化处理

E-mail:wangjun_ice@126.com



薛 磊

男,1963年生,教授,博士研究生导师,研究方向为信号处理、电子侦察数据分析

E-mail:eeixuelei@163.com



屠俑霖

男,2002年生,本科生,专业方向为网电对抗技术

E-mail:1597347145@qq.com



遇浩宁

男,2003年生,本科生,专业方向为网电对抗技术

E-mail:1292594247@qq.com



姜建华

女,1982年生,高级工程师,研究方向为雷达对抗系统设计

E-mail:jiangjianhua135@163.com



责任编辑 安 蓓