

基于多模特征融合的雷达干扰信号识别

魏赓力¹, 李凉海², 闫海鹏³, 李世宝¹, 杨 爽¹

(1 中国石油大学(华东)海洋与空间信息学院 青岛 266580;

2 中国航天电子技术研究院 北京 100094;

3 北京遥测技术研究所 北京 100076)

摘要: 传统制导雷达面临的新型有源干扰样式越来越复杂, 雷达必须对各种干扰类型加以鉴别。传统的干扰识别方法仅对特定单一样式有效, 通用性较差、泛化能力较弱, 无法应对复杂多变的干扰对抗环境。因此, 必须提出智能化更高、稳健性更强的普适干扰识别方法, 提升制导武器抗干扰能力。为了提高干扰信号识别的准确率, 研究了多模特征融合算法, 并最终对时域、时频域、信息论特征进行融合以实现分类。首次将信息论中熵、相对熵、相对距离等概念引入到干扰信号分类这个应用场景中, 通过仿真实验表明, 能够有效对常见干扰进行有效识别, 在较低干噪比下也有较好的识别准确率。

关键词: 雷达有源干扰; 信息论; 特征提取; 多模态分类

中图分类号: TN974; TN911.2 文献标志码: A 文章编号: 2095-1000(2023)04-0080-08

DOI: 10.12347/j.ycyk.20230328001

引用格式: 魏赓力, 李凉海, 闫海鹏, 等. 基于多模特征融合的雷达干扰信号识别[J]. 遥测遥控, 2023, 44(4): 80–87.

Radar jamming signal identification based on multimode feature fusion

WEI Gengli¹, LI Lianghai², YAN Haipeng³, LI Shibao¹, YANG Shuang¹

(1. College of Oceanography and Space Informatics, China University of Petroleum, Qingdao 266580, China;

2. China Aerospace Electronics Technology Research Institute, Beijing 100094 China;

3. Beijing Research Institute of Telemetry, Beijing 100076, China)

Abstract: The traditional guidance radar is facing increasingly complex new types of active interference patterns, and the radar must discriminate against various types of interference. The traditional interference recognition method is only effective for a specific single pattern, which has the disadvantages of poor generality and weak generalization ability, resulting in its inability to cope with the complex and changing interference countermeasures. Therefore, it is necessary to propose a more intelligent and robust universal interference recognition method to enhance the anti-interference ability of guided weapons. In order to improve the accuracy of interference signal recognition, this paper studied the multi-mode feature fusion algorithm, and finally fused time-domain, time-frequency domain, and information theory features to achieve classification. This paper introduces for the first time the concepts of entropy, relative entropy, and relative distance in information theory into the application scenario of interference signal classification. Through simulation experiments, it is shown that this method can effectively identify common interference and has good recognition accuracy even at low jam-to-noise ratios.

Keywords: Active radar interference; Information theory; Feature extraction; Multi-modal classification

Citation: WEI Gengli, LI Lianghai, YAN Haipeng, et al. Radar jamming signal identification based on multimode feature fusion[J]. Journal of Telemetry, Tracking and Command, 2023, 44(4): 80–87.

引 言

在现代战争中, 主动干扰已成为电子战中不可或缺的技术手段^[1]。雷达对抗技术主要包括雷达

干扰和雷达抗干扰。雷达干扰指利用发射电磁信号对敌方雷达进行破坏, 使其不能正常工作。而雷达抗干扰指检测、分析和抑制可能存在的干扰从而提高雷达的探测能力。当前, 按照干扰机制分为有源

干扰和无源干扰,其中有源干扰可对雷达造成不可估量的损害,被广泛应用于电子对抗。同时随着数字射频存储技术(Digital Radio Frequency Memory, DRFM)的应用与发展^[2],干扰机的出现加剧了雷达面临的威胁。作为雷达抗干扰系统的前提和基础,有源干扰识别具有极其重要的研究意义。

针对雷达有源干扰识别问题,学者们进行了大量的研究。文献[3]通过提取7种特征参数使用支持向量机对典型压制和欺骗干扰进行识别,总体识别率在94%以上,但不同干扰之间的识别率差异较大。文献[4]分析了六种具有代表性的干扰信号模型域之间的特征值差异,将提取的奇异值分布(Singular Value Decomposition, SVD)和瞬时频率(Instantaneous Frequency, IF)组成的二维参数送入BP神经网络(Back Propagation Neuron Network)进行训练与识别,该模型训练速度快且所需样本小,但总体识别准确率欠佳。文献[5]采用基础的CNN结构对9种典型干扰的STFT(Short-Time Fourier Transform, 短时间傅里叶变换)时频图进行识别分类,在干噪比(Jammer-to-Noise Ratio, JNR)处于0~8dB情况下达到了98.667%的识别率,但该方法未对低干噪比下的识别率进行探讨。总体来说雷达干扰的识别步骤一般为^[6]:在有源干扰信号识别的过程中,先确定是否存在干扰,经过去噪等预处理后,将信号输入到下一步;然后信号的特征提取集中于将信号变换到多个域中,提取易于区分各类有源干扰的特征参数,以此去除冗余信息,实现信号的降维处理;最后,将得到的各类特征参数输入到设计好的分类器中进行识别。

当前,国内外大量学者主要使用了单种模态的信号特征来对信号进行分类,这导致在特征提取过程中会遗漏某些关键信息从而导致模型的识别率不佳、拓展性不够。为进一步加强雷达干扰识别性能,本文将对常规噪声干扰和欺骗干扰进行时域、时频域的特征分析,同时分析信息论中熵、相对熵、相对距离等概念在干扰信号分类中应用的可能性。基于此设计一个多模特征融合的干扰信号识别模型,减少了单种模态所提取特征的局限性,使模型泛化能力更强,实现更通用的干扰识别方法。

1 基于参数的干扰信号生成

有源干扰技术通常分为两大类^[7]:欺骗性干扰

和压制性干扰。欺骗性干扰通过截获转发雷达发射信号,叠加虚假目标数量、虚假目标距离、速度和角度等假目标信息,以迷惑雷达并影响其进一步行动。压制性干扰主要是通过类噪声的信号掩盖目标的真实回波信号来干扰雷达检测目标的信息。为了使分类器“见多识广”,本研究使用的信号干扰类型基本覆盖了目前有源干扰的各个类型。

雷达发射信号主要有脉冲信号、LFM(Linear Frequency Modulation, 线性调频)信号等形式,而LFM信号以其距离分辨率高、抗噪特性强等优势成为目前最常采用的发射信号形式。假设雷达发送LFM信号 $s_l(t)$,其表达式为:

$$s_l(t) = \text{rect}\left(\frac{t}{T}\right) e^{j2\pi\left(f_0 t + \frac{k}{2} t^2\right)} \quad (1)$$

式中, f_0 代表起始频率, T 代表脉冲重复周期, k 为调频斜率, $k=B/\tau$, B 代表带宽, τ 代表脉宽, $\text{rect}(\cdot)$ 为矩形函数。

在此基础上,本文共研究了射频噪声干扰、噪声调幅干扰、噪声调频干扰、距离托引干扰、噪声卷积干扰、噪声乘积干扰、间歇采样转发干扰和切片重构干扰八类干扰信号。本文干扰信号的模型与真实干扰信号的模型相同,根据公开文献仿真产生相应的干扰信号数据集^[8-11],通过仿真实验验证后续多模特征融合模型的有效性,不同干扰信号数据集的生成参数表见表1。

正常情况下信号如果不做积累将淹没在噪声中,在上述干扰信号基础上叠加JNR范围为-10 dB~11 dB(抽样间隔为3 dB,共8个点)的高斯白噪声,从而模拟真实雷达回波场景。对于JNR大于10 dB的情况,其干扰特征更加明显易于被网络识别,因此不做研究考量。采用蒙特卡罗^[12]仿真法使得每个干扰样式在单个JNR下的训练与测试集数量为500和100,共计32 000个训练样本和6 400个测试样本。确保了所有干扰信号都有效地抑制或欺骗了目标信号。对于同种干扰信号,训练集和测试集中的样本干扰样式相同,但参数不同,使得训练的网络能够有效识别未知干扰信号。

2 基于时频分析和信息论的特征提取

理论上,无论什么类型的干扰都会与真实的回波存在差异。这种差异在时域、频域、时频域

表 1 干扰数据集生成参数取值范围表

Table 1 Interference data set generation parameter value range table

干扰类型	共同参数	特殊参数
射频噪声干扰		噪声功率/dBw 0.1:10
噪声调幅干扰		噪声标准差 0.001: 0.1 噪声带宽/Hz 1E6:5E6
噪声调频干扰		噪声标准差 0.001:0.1 噪声带宽/Hz 1E6:5E6
距离拖引干扰	载波频率/MHz 20:40 带宽/MHz 5: 15 脉冲重	多普勒频率/Hz 1E4: 10E4
噪声卷积干扰	复周期/ μ s 300: 600 采 样频率/MHz 150	噪声功率/dBw 0.1: 5
噪声卷积干扰		噪声功率/dBw 0.1: 5
间歇采样转发干扰		转发次数 1:10 采样次数 1:10
切片重构干扰		切片数量 1:10 切片 复制次数 1:5

或者其他变换域上能够体现。因此, 本研究主要分别通过融合时频域特征、时域特征和信息论特征来对干扰信号进行识别。

2.1 基于时频分析的特征提取和融合

2.1.1 时频域特征提取

与单独的频域特征相比, 时频特征包含了信号的能量在时间和频率空间内的分布, 能更全面地包含信号所蕴含信息。文献[13]通过研究发现, 不同时频分布所携带的信息之间有所差异, 进而可以影响最终识别效果。本研究通过把雷达信号变换成 CWD (Choi-Williams Distribution, 崔-威廉斯分布) 图像和 SPWVD (Smooth and Pseudo Wigner-Ville Distribution, 平滑伪维格纳-威利分布) 图像, 使用时频特征融合模型对提取的时频图像进行特征融合, 为下一步分类做准备。

CWD 是雷达信号最广泛的时频变换方法之一, 因为它不仅通过引入核函数将雷达信号详细表达出来, 而且还能有效地防止交叉项的出现, 其表达式定义为:

$$C(t, \omega) = \iiint_{\infty} e^{j2\pi\zeta(s-t)} f(\zeta, \tau) \cdot x(s+t/2) \cdot e^{-j\omega\tau} d\zeta ds d\tau (2)$$

式中, $C(t, \omega)$ 指的是进行 CWD 变换后得到的结果, t 和 ω 分别表示时间轴和角频率; $f(\zeta, \tau)$ 表示核函

数, 其表达式为:

$$f(\zeta, \tau) = e^{(\pi\zeta\tau)^2/2\sigma} (3)$$

指数核函数包括一个 σ 参数, 用于抑制远离水平轴和垂直轴的交叉项, 因此 CWD 不会抑制具有相同时间中心或频率中心的两个自动项生成的交叉项。为了平衡交叉项和时频图像的分辨率, 在本文中将 σ 设为 1。

SPWVD 变换是基于 WVD (Wigner-Ville 分布) 的一种变换, 它通过对 WVD 进行平滑处理来消除 WVD 中的交叉项。这样可以获得一个更清晰的时频表示, 使得信号的频率和时域信息更容易识别和解释。相比于其他时频分析方法, SPWVD 变换具有更好的分辨率和更少的噪声干扰。数学表达式如下:

$$S(t, \omega) = \iint x(t-v+T/2) \cdot x^*(t-v-T/2) \cdot h(T)g(v) e^{-j\omega v} dv dT (4)$$

式中, $S(t, \omega)$ 表示获得的 SPWVD 变换结果; t 和 ω 分别表示时间轴和角频率; x^* 是 x 的共轭; $h(T)$ 和 $g(v)$ 是窗口函数, 其中函数 $g(v)$ 是沿时间轴平滑交叉项, 函数 $h(T)$ 则是沿频率轴平滑交叉项。时域和频域中的平滑量可以通过窗口函数的长度来控制, $x(t)$ 表示干扰信号 $r(t)$ 的解析信号, 定义为:

$$x(t) = r(t) + jH[r(t)] (5)$$

式中, $H[r(t)]$ 表示对干扰信号 $r(t)$ 做希尔伯特变换。

2.1.2 时频特征融合网络

通过上述两种时频变换方式提取到雷达信号的时频图像后, 将两种时频图像调整为统一尺寸并进行归一化处理。为了充分利用不同时频图像之间的差异进而获取更多特征, 使用密集卷积神经网络^[14] (DenseNet) 对两种时频图像进行提取然后通过融合网络进行特征融合, 这种做法既包含单一时频模态的特征, 也考虑了两种模态的特征之间的关系。具体步骤如下:

① 首先对一维的干扰信号进行 CWD 和 SPWVD 变换, 获得二维时频图 TFI (Time-Frequency Image), 接着采用二维维纳滤波来抑制 TFI 的噪声。使用双线性插值将 TFI 的大小调整为 224×224 像素, 并对 TFI 的振幅进行归一化, 可降低从网络模型中提取特征的计算复杂度, 这样就可以制作成 CWD 图像数据和 SPWVD 图像数据集。

② 对于 CWD 图像数据和 SPWVD 图像, 首先经过 DenseNet 进行特征提取, 其结构由 5 个 Dense

Block模块和4个Transition Layer层组成。该模型除去第1层外,其他层都包括该层前面每一层的特征图,使得连接更加稠密且比传统网络需要更少的参数的同时也可减少特征丢失。然后将提取的特征送入一个核大小为 1×1 和 3×3 的卷积层和全局平均池化层组成的特征融合网络,输出CWD图像数据和SPWVD图像的融合特征。通过将两种时频图像送入时频域特征融合网络中,从而输出两种时频数据的融合特征。

在特征融合模型中选择使用Jensen-Shannon(JS)^[15]散度作为惩罚项以确保模型对相似的输入产生一致且相似的预测。

$$JS(p\|q) = \frac{1}{2} KL\left(p\left\|\frac{p+q}{2}\right.\right) + \frac{1}{2} KL\left(q\left\|\frac{p+q}{2}\right.\right) \quad (6)$$

式中, p 和 q 分别表示两种概率分布,模型的损失函数 $L(\theta)$ 定义如下:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N JS(t_i\|p_{\theta^c}(x_i^c)) + \frac{\mu}{2} (\theta^c)^2 + \frac{1}{N} \sum_{m=1}^2 \sum_{i=1}^N JS(p_{\theta^m}(x_i^c)\|p_{\theta^m}(x_i^m)) + \frac{\mu}{2} (\theta^m)^2 \quad (7)$$

时频特征融合模型如图1所示。




图1 时频特征融合模型

Fig. 1 Time-frequency feature fusion model

2.2 基于信息论的特征提取

文献[16]曾利用信息熵来对灵巧噪声干扰进行识别,证明了熵的信息包含了干扰信号和真实回波信号之间的差异。因此,本节提出基于信息熵和相对距离的方法,将信息熵、相对熵、相对距离应用于雷达干扰识别中。

信息熵(又名香农熵)是由香农提出的可以定量地评估衡量信源的平均不确定度的一种指标,此处将随机变量 X 的期望命名为“熵”:

$$H(X) = E[I(X)] = \sum_{i=1}^n P(X_i) I(X_i) = - \sum_{i=1}^n P(X_i) \log P(X_i) \quad (8)$$

式中,随机变量 X 的可能取值为 X_i ,其中 $P(X_i)$ 表示 X_i 发生的概率。

KL散度^[17]在信息论中被称为“相对熵”,用于衡量两个分布 P 和 Q 之间的差异,其定义式如下所示:

$$KL(P\|Q) = \sum_{i=1}^n P(X_i) \log \frac{P(X_i)}{Q(X_i)} \quad (9)$$

从上式可以看出,若 P 和 Q 越相似(即 $P(X_i)$ 越接近于 $Q(X_i)$),则 $\log \frac{P(X_i)}{Q(X_i)}$ 越趋于0,最终使得

$KL(P\|Q)$ 也趋于0,这是容易理解的,因为相对熵是差异性的衡量,若两个分布越接近肯定差异越小。同时将相对熵里的求和项单独计算,并定义为相对距离:

$$RD(P\|Q) = P(X_i) \log \frac{P(X_i)}{Q(X_i)} \quad (10)$$

下面是提取信息熵和熵的相对距离的流程:

- ① 对仿真后的干扰回波数据进行FFT变换,把信号转化为频域信息。
- ② 除去信号带宽外的噪声,然后对带宽内进行归一化处理。
- ③ 对频谱幅度进行归一化,计算各频率能量占总能量的比例,记为 $E = \{e_1, e_2, \dots, e_n\}$ 。
- ④ 根据式(8)和式(10)计算各干扰信号的信息熵和相对距离。

3 多模特征融合的干扰信号识别模型

近年来,国内外学者针对雷达有源干扰识别已经提出了很多算法,主要分为基于人工提取特征的传统方法和采用时频分析与机器学习相结合的人工智能算法^[18](如AlexNet模型),前者提取的特征同时包含时、频域特征,但受人为影响其并不适用于多种场景。后者研究大多通过时频分析将雷达波信号转换为时频图像,使用二维卷积神经网络对单模态数据进行特征提取、融合和分类。然而,单模态的数据存在信息冗余、鲁棒性差和系统过拟合等缺陷。因此,本文提出的多模特征融合算法能更好地提取时间频率特征、综合分析不同模态的信息和充分挖掘多模态数据之间的关联,从而有效提高泛化能力和准确率。

该模型采用的数据源总共包含三种,分别为:原始信号的时域特征、前一节生成的时频融合特征和生成熵与相对距离的特征。此外,该模型加入了注意力机制,不仅能动态地对目标任务中最

有意义的特征信息赋予更强的权重并减少不重要信息的影响, 还可以更好地发掘不同数据之间的相关性。

多模态分类模型框架如图 2 所示, 与数据源相对应的多模态融合算法主要由三个部分组成, 分别为处理信息论数据的信息分支、处理原始数据的时域分支和处理时频数据的时频分支。信息分支和时域分支主要由残差模块构成, 信息论数据和原始数据分别经过 7×7 卷积层和 3×3 最大池化层, 接着经过两种不同类型的残差模块, 该残差模块主要由 1×1 和 3×3 卷积层构成, 其中 1×1 卷积核实现了对特征向量的升/降维和非线性映射。此时, 时频数据经过两个卷积层与其他两组数据一起通过跨模态注意力模块来进行交互处理。类似的, 信息分支和时域分支分别经过残差模块、时频数据经过卷积层后, 三者通过跨模态融合, 如此反复两次, 形成最后的跨模态融合模块, 接着分别通过平均池化和全连接层进行处理, 继而连

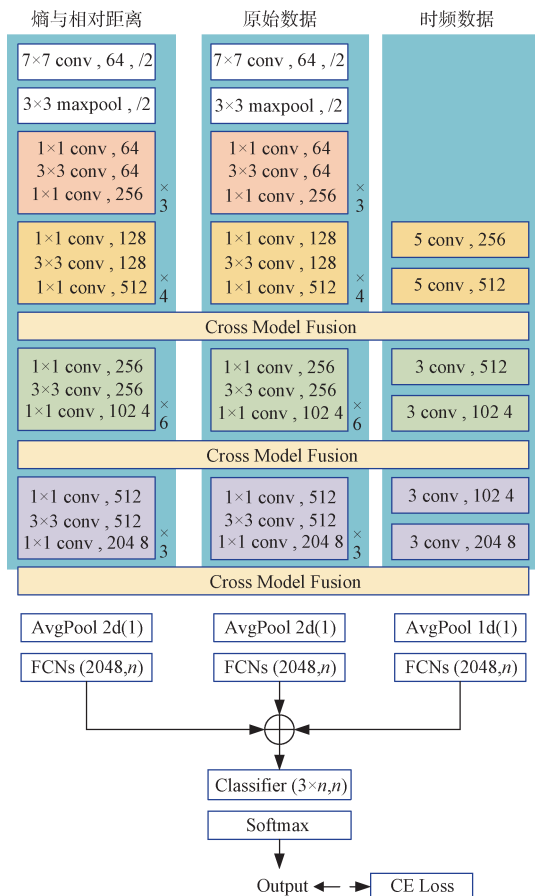


图 2 多模态分类模型框架

Fig. 2 Multimodal classification model framework

接成多维数组。最后我们构造了 Softmax 激活函数的线性层来实现雷达信号干扰的多元分类, 并将预测的分类结果与样本真实标签的交叉熵来解决目标优化问题。本文采用 Adam 优化器迭代更新多模态融合网络的连接权重, 学习率为 0.000 1, 采用余弦退火衰减策略提高训练速度, batch size 为 32。

本文多模态分类模型的核心是时频域、时域和信息数据的跨模态融合, 如图 3 所示, 当数据经过卷积层后被分离成不同的特征 $F = \{f_1, \dots, f_N\}$, 它们通过残差映射成查询向量 $Q = \{q_i\}$, 键向量 $K = \{k_i\}$ 和值向量 $V = \{v_i\}$, 那么用残差模块构建自注意力机制的特征向量为 $A = \text{MHA}(Q, K, V)$ 。在图 2 的整个多模态分类模型中共应用了 3 次跨模态融合, 假设将第 i 次跨模态处理的特征图表示为 $F_{TF/TI}^{(i)}$, 其中 TF 、 T 和 I 分别表示相应的时频、时域和信息分支, 其特征映射向量依次是 $Q_{TF/TI}^{(i)}$ 、 $K_{TF/TI}^{(i)}$ 和 $V_{TF/TI}^{(i)}$, 那么可以分别构建第 i ($i \neq j$) 个分支的查询向量 Q 与第 j 个分支的键向量 K 、值向量 V 的交叉注意力, 则跨模态的方式共可以分为三种, 如下式:

$$A_{TF} = \text{MHA}(Q_{TF}, K_T, V_T) \quad (11)$$

$$A_T = \text{MHA}(Q_T, K_I, V_I) \quad (12)$$

$$A_I = \text{MHA}(Q_I, K_{TF}, V_{TF}) \quad (13)$$

式中, A_{TF} 表示为时频分支和时域分支之间的跨模态注意力, 时域与信息分支的跨模态注意力为 A_T , 信息与时频分支的跨模态注意力 A_I 。此外, 为了公式的简洁明了忽略表示特征图层的上标。如图 3 所示, 在计算完成三个注意力 A_{TF} 、 A_T 和 A_I 后, 分别采用全局平均池化函数(GAP)对其进行降

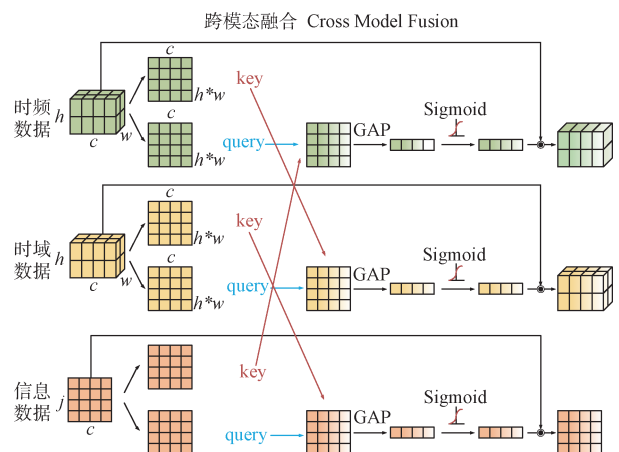


图 3 跨模态融合 CMF 框架

Fig. 3 Cross-modal fusion CMF framework

采样处理以防止过拟合,以 Sigmoid 为激活函数使各通道的取值范围映射至 0~1,若通道值越接近 1 则说明其重要性也越高,称之为影响权重。然后将原始特征图与影响权重进行矩阵乘积运算 Θ ,具体运行公式如下所示:

$$\tilde{F}_{TF} = \sigma(\text{GAP}(A_{TF})) \Theta F_{TF} \quad (14)$$

$$\tilde{F}_{TF} = \sigma(\text{GAP}(A_{TF})) \Theta F_{TF} \quad (15)$$

$$\tilde{F}_T = \sigma(\text{GAP}(A_T)) \Theta F_T \quad (16)$$

$$\tilde{F}_I = \sigma(\text{GAP}(A_I)) \Theta F_I \quad (17)$$

传统的神经网络分类器主要由多个全连接层或最大池化层组成,但其往往存在网络维度较高、长程依赖等问题,只能捕捉到图像的局部信息,且往往需要采用正则化等技术来避免过拟合。为了解决上述问题,如图 4 所示,其特征提取部分为 \tilde{F}_{TF} 、 \tilde{F}_T 和 \tilde{F}_I ,采用多层感知机 MLP^[19]以替换传统的神经网络分类结构,同时以高斯误差线性单元 GeLU 作为激活函数,并使用 dropout 层降低过拟合的风险,激活函数 GeLU(x)的近似表达式如式(18)所示。值得注意的是,ReLU 函数在零点处不可微,而且由于具有一定的稀疏特性会使部分神经元失效,但 GeLU 作为非线性激活函数具有的随机正则性能在一定程度上保证神经网络的非线性和泛化性。




图4 分类器结构

Fig. 4 Classifier structure

$$\text{GeLU}(x) = x * \sigma(1.702x) \quad (18)$$

输入特征图 $X_{in} \in \mathbb{R}^{H \times W \times C}$ 将被送入一个 1×1 的点卷积层,其主要作用是提取局部特征和改变矩阵维度,该层输出的特征图为 $X_1 \in \mathbb{R}^{H \times W \times C'}$;然后采用 patch embedding 来重塑特征图和压缩图像补丁,则特征图 X_1 将重塑为 N 个扁平化的二维补丁 X_p^i 的序列,如下式:

$$X_p^i = P \times P \times C, i \in \{1, 2, \dots, N\} \quad (19)$$

式中, $P \times P$ 是第 i 个特征图的分辨率, $N = H \times W / P^2$ 是生成的特征图数量,为了使数据能够被 MLP 层处理,将 X_p^i 通过可训练的线性投影压缩至一个 D

维嵌入空间。则 patch embedding 层的输出特征图 X_2 表达式如下:

$$X_2 = [X_p^1 E; X_p^2 E; \dots; X_p^N E] + E_{\text{pos}} \quad (20)$$

式(20)中, $E \in \mathbb{R}^{(P^2 \times C) \times D}$ 是特征图的嵌入投影, $E_{\text{pos}} \in \mathbb{R}^{N \times D}$ 代表嵌入位置, X_2 是编码嵌入后的特征图序列。将处理后的特征图序列 X_2 送入 MLP 层处理,表达式如下:

$$X_2' = \text{Dropout}(\text{GeLU}(\text{FC}(X_2))) \quad (21)$$

$$X_3 = \text{Dropout}(\text{FC}(X_2')) \quad (22)$$

在式(21)和式(22)中, GeLU 和 Dropout 用于防止网络过拟合并提高训练准确度, FC 是一个全连接层,其主要目的是将二维特征图的卷积输出转换为二维向量。数据通过 MLP 层的输出将被重新排列成输入长度为 n 的时域特征向量,并通过分类器预测干扰信号类别,最后由 Softmax 给出每个类别的可能性。

4 实验结果与分析

如前所述,本文主要是对射频噪声干扰、噪声调幅干扰、噪声调频干扰、距离拖引干扰、噪声卷积干扰、噪声乘积干扰、间歇采样转发干扰和切片重构干扰八种单类型的干扰信号进行识别。

将测试集输入到训练好的特征融合分类模型中,得到的混淆矩阵如图 5 所示。从混淆矩阵可知,当 JNR 处于 $-10 \text{ dB} \sim -11 \text{ dB}$ 时,基于多模特征融合的雷达有源干扰识别模型总体识别准确率为 99.21%,其中 6 种干扰的识别准确率在 99.6% 以上,各干扰的识别准确率均在 96.8% 以上。

为了研究识别准确率与 JNR 的关系,绘制了不同 JNR 下不同干扰的识别准确率折线图。如图 6 所示,当 JNR 大于 -1 dB 时,这 8 种典型的雷达有源干扰信号的识别准确率都可以达到 99% 以上。而随着 JNR 不断下降,间歇采样转发干扰和切片重构干扰的识别准确率出现了明显的下降趋势。

同时为了验证多模特征识别方法相较于单模特征识别方法在准确率上的提升,采用文献[20]和文献[21]提出的方法在同一干扰数据集上进行训练,并绘制了三种方法在不同 JNR 下的整体识别性能曲线。如图 7 所示的实验结果表明,当 $\text{JNR} > -1 \text{ dB}$ 时,所有识别方法的整体识别率均能保持在 97.8% 以上。然而在相对较低的 JNR 条件下,传统的 SVM(Support Vector Machine, 支持向量机)分类




图 5 多模融合分类模型测试集混淆矩阵结果

Fig. 5 Multi-mode fusion classification model test set confusion matrix results




图 6 测试集识别准确率随 JNR 变化图

Fig. 6 Test set recognition accuracy with JNR change chart

器及 VGG16 网络识别准确率明显降低。而本文方法在不同 JNR 情况下都具有较好的识别性能。

5 结束语

本文设计了一个多模特征融合的干扰信号分类模型, 该模型既考虑了现有的基于时频分析的特征, 也创新性地信息论中相关概念引入到干扰信号分类领域中, 然后与最原始的时域信号进行跨模态的特征融合后进行分类, 现有实验表明: 本文所设计的模型在多模态特征融合背景下可以取得最优的整体性能, 可减少单模态特征泛化能

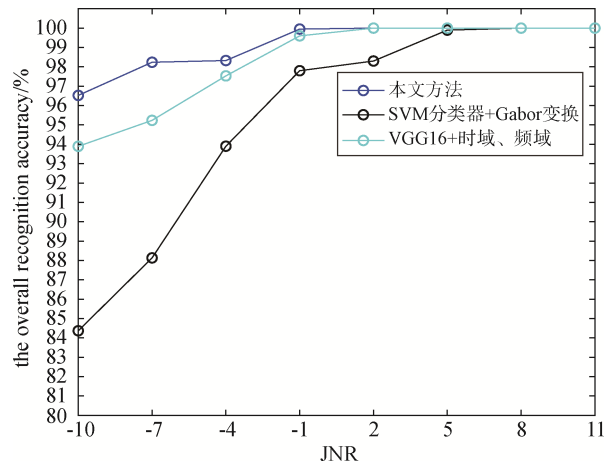


图 7 不同干扰识别算法的总体识别准确率随 JNR 变化图

Fig. 7 The overall recognition accuracy of different interference recognition algorithms varies with JNR

力差的风险。尽管本文的实验结果是比较令人满意的, 但是也必须指出还存在着一些问题和可改进的方向: 一是为了让训练的模型更加具有实用价值, 应该用更多的真实雷达回波去训练; 二是目前高准确率的方法都是基于深度学习方法实现的, 而深度学习方法的计算参数量过高会导致系统的实时性不够强, 可对模型进行轻量化方面的设计以达到更为有效的应用。

参考文献

- [1] 丁鹭飞, 耿富录. 雷达原理(第3版)[M]. 西安: 西安电子科技大学出版社, 2002.
- [2] SOUMEKH M. SAR-ECCM using phase-perturbed LFM chirp signals and DRFM repeat jammer penalization[J]. IEEE Transactions on Aerospace & Electronic Systems, 2006, 42(1): 191-205.
- [3] XU C, YU L, WEI Y, et al. Research on active jamming recognition in complex electromagnetic environment[C]// 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP), 2019: 1-5.
- [4] SUN P, YU J, HAO W. Research on radar active jamming recognition based on 2-D time-frequency features[C]// IEEE 2021 3rd International Academic Exchange Conference on Science and Technology Innovation (IAECST), 2021: 777-781.
- [5] LIU Q, ZHANG W. Deep learning and recognition of radar jamming based on CNN[C]//IEEE 2019 12th Interna-

- tional Symposium on Computational Intelligence and Design (ISCID), 2019, 1: 208-212.
- [6] 周红平, 王子伟, 郭忠义. 雷达有源干扰识别算法综述[J]. 数据采集与处理, 2022, 37(1): 1-20.
ZHOU Hongping, WANG Ziwei, GUO Zhongyi. Overview on recognition algorithms of radar active jamming[J]. Journal of Data Acquisition & Processing, 2022, 37(1): 1-20.
- [7] 李永祯, 黄大通, 邢世其, 等. 合成孔径雷达干扰技术研究综述[J]. 雷达学报, 2020, 9(5): 753-764.
LI Yongzhen, HUANG Datong, XING Shiqi, et al. A review of synthetic aperture radar jamming technique[J]. Journal of Radars, 2020, 9(5): 753-764.
- [8] 鲍大祥. 雷达干扰分类判别方法研究[D]. 西安: 西安电子科技大学, 2015.
- [9] 席泽敏, 贺静波. 线性调频脉冲压缩雷达干扰仿真研究[J]. 现代雷达, 2005, 27(10): 5-7.
XI Zemin, HE Jingbo. A simulated study on jamming of LFM pulse-compression radar[J]. Modern Radar, 2005, 27(10): 5-7.
- [10] 王梓再. 基于深度学习的线性调频雷达有源干扰识别方法研究[D]. 成都: 电子科技大学, 2022.
- [11] 崔伟, 魏杰, 王琰琦. 基于间歇采样的LFM雷达干扰建模与仿真[J]. 舰船电子对抗, 2022, 45(6): 1-5, 44.
CUI Wei, WEI Jie, WANG Yanqi. Modeling and simulation of LFM radar jamming based on intermittent sampling[J]. Shipboard Electronic Countermeasure, 2022, 45(6): 5, 44.
- [12] JAMES F. Monte Carlo theory and practice[J]. Reports on Progress in Physics, 1980, 43(9): 1145.
- [13] 付亮. 雷达辐射源信号特征提取与识别技术研究[D]. 西安: 西安电子科技大学, 2019.
- [14] IANDOLA F, MOSKEWICZ M, KARAYEV S, et al. Densenet: Implementing efficient convnet descriptor pyramids[J]. arXiv preprint:1404.1869, 2014.
- [15] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//International Conference on Machine Learning, PMLR, 2017: 214-223.
- [16] 李杰然. 基于信息熵的灵巧噪声干扰识别方法[J]. 舰船电子工程, 2021, 41(12): 32-35.
LI Jieran. Method of smart noise jamming recognition based on Shannon entropy[J]. Ship Electronic Engineering, 2021, 41(12): 32-35.
- [17] 朱雪龙. 应用信息论基础[M]. 北京: 清华大学出版社, 2001.
- [18] 陈赓, 田波, 宫健, 等. 雷达有源干扰鉴别技术综述[J]. 现代防御技术, 2019, 47(5): 113-119.
CHEN Geng, TIAN Bo, GONG Jian. Overview of radar active jamming identification techniques[J]. Modern Defense Technology, 2019, 47(5): 113-119.
- [19] TOLSTIKHIN I O, HOULSBY N, KOLESNIKOV A, et al. Mlp-mixer: An all-MLP architecture for vision[J]. Advances in Neural Information Processing Systems, 2021, 34: 24261-24272.
- [20] JUNFEI Y, JINGWEN L, BING S, et al. Barrage jamming detection and classification based on convolutional neural network for synthetic aperture radar[C]//IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium, 2018: 4583-4586.
- [21] HAO Z, YU W, CHEN W. Recognition method of dense false targets jamming based on time-frequency atomic decomposition[J]. The Journal of Engineering, 2019, (20): 6354-6358.

[作者简介]

魏赓力 1997年生, 硕士研究生, 主要研究方向为雷达抗干扰技术。

李凉海 1965年生, 硕士, 研究员, 主要研究方向为雷达系统设计。

闫海鹏 1988年生, 高级工程师, 主要研究方向为雷达成像和雷达对抗技术。

李世宝 1978年生, 教授, 博士生导师, 主要研究方向为移动计算和信号处理。

杨爽 1998年生, 硕士研究生, 主要研究方向为目标识别和深度学习。

(本文编辑: 杨秀丽)