

面向小样本的多模态雷达有源欺骗干扰识别方法

张顺生^{*①} 陈爽^① 陈晓莹^② 刘莹^② 王文钦^③

^①(电子科技大学电子科学技术研究院 成都 611731)

^②(中国科学院大学计算机科学与技术学院 北京 100190)

^③(电子科技大学信息与通信工程学院 成都 611731)

摘要: 干扰识别是雷达抗干扰的前提,但对于实际的雷达欺骗干扰识别,存在着样本数量不足的问题。针对此问题,该文提出一种面向小样本的多模态雷达有源欺骗干扰识别方法。该方法基于雷达信号提取的特征参数及时频图像两种模态信息,利用原型网络训练多模态特征,并借助图像降噪处理和加权欧氏距离提高低信噪比下的识别性能,实现小样本条件下的雷达欺骗干扰识别。仿真结果表明,该文所提方法在干信比为3 dB时,10种雷达欺骗干扰的平均识别准确率达到97%以上。模拟器数据的测试结果表明所提方法具备良好的泛化能力。

关键词: 雷达有源欺骗干扰;多模态;小样本;原型网络;干扰识别

中图分类号: TN958

文献标识码: A

文章编号: 2095-283X(2023)04-0882-10

DOI: 10.12000/JR23104

引用格式: 张顺生,陈爽,陈晓莹,等.面向小样本的多模态雷达有源欺骗干扰识别方法[J].雷达学报,2023,12(4):882-891. doi: 10.12000/JR23104.

Reference format: ZHANG Shunsheng, CHEN Shuang, CHEN Xiaoying, et al. Active deception jamming recognition method in multimodal radar based on small samples[J]. *Journal of Radars*, 2023, 12(4): 882-891. doi: 10.12000/JR23104.

Active Deception Jamming Recognition Method in Multimodal Radar Based on Small Samples

ZHANG Shunsheng^{*①} CHEN Shuang^① CHEN Xiaoying^②

LIU Ying^② WANG Wenqin^③

^①(*Research Institute of Electronic Science and Technology, University of Electronic Science and Technology of China, Chengdu 611731, China*)

^②(*School of Computer Science and Technology, University of Chinese Academy of Sciences, Beijing 100190, China*)

^③(*School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China*)

Abstract: Jamming recognition is a prerequisite for radar anti-jamming and actual radar deception jamming recognition; however, there is a problem of insufficient samples. To address this issue, we propose a multimodal radar active deception jamming recognition method based on small samples in this paper. This method is based on two modal information—feature parameters and time-frequency images extracted from radar signals—and utilizes prototype networks to train multimodal features. Furthermore, the model adopts the image denoising method and weighted Euclidean distance to improve the recognition performance at low signal-to-noise ratios. Thus, radar deception jamming recognition can be achieved under small sample conditions. Simulation results reveal that the proposed method achieves an average recognition accuracy of over 97% across 10 types of radar

收稿日期: 2023-06-11; 改回日期: 2023-07-22; 网络出版: 2023-08-15

*通信作者: 张顺生 zhangss@uestc.edu.cn *Corresponding Author: ZHANG Shunsheng, zhangss@uestc.edu.cn

基金项目: 国家部委基金

Foundation Item: The National Ministries Foundation

责任编辑: 毕大平 Corresponding Editor: BI Daping

deception jamming when the jamming-to-signal ratio is 3 dB. Moreover, the test results from the simulator data verify the good generalization performance of the proposed method.

Key words: Radar active deception jamming; Multimodal; Small samples; Prototypical networks; Jamming recognition

1 引言

随着电子干扰技术的发展,特别是数字射频存储(Digital Radio Frequency Memory, DRFM)技术的出现^[1],调制方式多样参数多变的雷达有源欺骗干扰给雷达带来了前所未有的威胁。为了抑制有源欺骗干扰信号对雷达正常工作的影响,采取相应的抗干扰措施是必要的。从逻辑上讲,雷达对干扰的识别和抑制是相互依存的两个环节。在这个过程中,需要准确地检测干扰信号,并对干扰进行分类和识别,然后针对性地采取相应的抗干扰措施来削弱或消除干扰。因此,正确识别多样的雷达有源欺骗干扰信号,可以为复杂电磁环境下雷达抗干扰提供决策。

目前,已有不少学者将人工智能算法应用于雷达欺骗干扰的识别^[2,3],并取得了一定的成果。Mendoza等人^[4]、Wu等人^[5]在提取多域特征后,利用支持向量机和BP (Back Propagation)神经网络进行干扰信号的识别,但提取的特征容易受到干噪比的影响,阈值难以设置;Zhao等人^[6]以时域信号为输入,借助LeNet网络对7种不同参数的雷达压制类干扰完成了识别;Liu等人^[7]借助OS-CFAR算法和时频处理提取特征,使用卷积神经网络(Convolutional Neural Network, CNN)实现了包括3类压制干扰6类欺骗干扰在内的9种干扰的识别。这些研究根据不同的需要选取相应的特征,借助神经网络实现干扰识别。但是这些方法都需要大量的干扰样本来支撑训练,而在实际环境中,很难获取到足够的样本,因此,基于小样本的雷达有源欺骗干扰识别具备重要的现实意义与应用价值。

自2005年来,小样本识别在机器视觉等方面取得了不少成果^[8-10],并且被应用于雷达干扰识别方向。Shao等人^[11]针对训练样本有限的问题,提出了一种基于CNN和孪生网络进行雷达干扰信号分类的方法,实现了小样本下的干扰识别。但孪生网络主要衡量的是两个输入的关系,即相似性,在干扰参数改变或个体差异较大时,检测性能会有所下降。陈泽伟等人^[12]针对毫米波雷达时频域干扰面临的实测样本不足的问题,使用深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Networks, DCGAN)来对数据进行增广,提高了CNN模型的干扰抑制性能。但并非所有数据集都

适合于应用GAN进行增广,例如,低分辨率的图像数据集,利用GAN扩充数据集时需要很长时间才能达到收敛,且收敛后的样本模糊度较高。Koch等人^[13]提出多模态单样本学习算法,将语音信号与对应图像进行匹配训练,实现小样本下的语音信号分类。

针对目前存在的训练样本不足、低信噪比下识别率低等问题,本文提出一种基于小样本的多模态雷达有源欺骗干扰识别方法。以雷达信号处理的手段,提取信号的特征参数与时频图像作为两个模态的输入,借助原型网络^[14](Prototypical Networks, PN)训练多模态特征,并利用图像预处理和加权欧氏距离提高低信噪比下的识别率,实现了小样本下的雷达有源欺骗干扰识别。

2 干扰信号的特征提取

目前的雷达有源欺骗干扰主要是通过DRFM干扰机对截获到的雷达信号幅度、时延、多普勒频率等进行调制之后形成的转发式欺骗干扰信号。本文选取典型的10种雷达欺骗干扰样式作为研究对象,分别为距离维密集假目标(Range Multi-false-Target, RMT)干扰、速度维密集假目标(Velocity Multi-false-Target, VMT)干扰、距离-速度联合密集假目标(Range-Velocity Multi-false-Target, RVMT)干扰、切片重构(Chopping and Interleaving, C&I)干扰、间歇采样转发干扰(Interrupted Sampling Repeater Jamming, ISRJ)、频谱弥散(Smeared Spectrum, SMSP)干扰、卷积调制灵巧噪声干扰(Smart Noise Jamming)、距离拖引(Range Gate Pull-Off, RGPO)干扰、速度拖引(Velocity Gate Pull-Off, VGPO)干扰,以及距离-速度联合拖引(Range-Velocity Gate Pull-Off, RVGPO)干扰。

雷达接收端的采样信号一般为真实回波信号、干扰信号与噪声的叠加,记为

$$r(n) = s(n) + j(n) + y(n) \quad (1)$$

其中, $s(n)$ 表示真实回波信号, $j(n)$ 表示干扰信号, $y(n)$ 表示随机噪声,针对式(1)所示接收信号模型进行干扰识别^[15,16]。

短时傅里叶变换(Short-Time Fourier Transform, STFT)是一种常用的提取时变非平稳信号特

征的时频分析方法, 因其算法简单而被广泛应用于雷达信号处理中, 离散形式的STFT定义如下:

$$F(n, k) = \sum_{i=0}^{N-1} x(n+i)w(i)e^{-j\frac{2\pi}{N}ik}, k = 0, 1, \dots, N-1 \quad (2)$$

其中, N 表示信号长度, $x(n)$ 表示输入时域信号序列, $w(i)$ 表示窗函数, 随着 n, k 的变化, 式(2)便有了时频分析能力。

与单独的时域或频域特征相比, 短时傅里叶变换能够得到信号能量分布与时间和频率的关系, 具有更直观的物理意义, 且在预处理过程中不易丢失特征。与其他时频处理方法相比, 短时傅里叶变换的计算复杂度低, 可降低处理过程的时间复杂度。因此, 选取短时傅里叶变换后的时频图像作为主要特征进行雷达有源欺骗干扰的识别^[17]。

为了更好地利用时频图像对干扰进行识别, 以及尽可能地降低随机噪声对于识别结果的影响, 需要先对时频图像进行相应的预处理。首先, 需要对图像进行线性灰度变换, 使噪声和信号之间的灰度值拉大来实现灰度图像增强。假设一幅图像 $f(x, y)$ 的原始灰度范围在 $[a, b]$ 之间, 经过线性变换后的图像 $g(x, y)$ 的灰度范围在 $[c, d]$ 之间, 则图像 $f(x, y)$ 中任意像素点的灰度值 k , 变换后得到图像 $g(x, y)$ 中对于像素点灰度值 l 可表示为

$$l = \begin{cases} c, & k = a \\ \frac{d-c}{b-a}(k-a) + c, & a < k < b \\ d, & k = b \end{cases} \quad (3)$$

图像增强后, 采用形态学闭运算^[18]对时频图像进行降噪处理。闭运算为先膨胀运算, 再腐蚀运算, 看

上去将两个细微连接的图块封闭在一起, 闭运算能够弥合小裂缝, 并保持总的位置和形状不发生改变。其中集合 A 被集合 B 膨胀, 可以表示为 $A \oplus B$, 其定义为

$$A \oplus B = [A^c \ominus (-B)]^c \quad (4)$$

其中, A 称为输入图像, B 称为结构元素, A^c 为 A 的补集。在数字图像处理中, 集合 B 又被称为结构元。

集合 A 被集合 B 腐蚀, 表示为 $A \ominus B$, 其定义为

$$A \ominus B = \{x : B + x \subset A\} \quad (5)$$

其中, $A \ominus B$ 由将 B 平移 x 但仍然包含在 A 内的所有点 x 组成。

图像的闭运算可以表示为

$$D_c(A, B) = (A \oplus B) \ominus B \quad (6)$$

设定信号载波为5.5 GHz, 带宽为10 MHz, 信噪比为-8 dB, 图1和图2为经过预处理前后10种干扰的时频图像, 仿真时取 $a = 0.1, b = 0.8, c = 0.1, d = 0.4$ 。对比图1和图2不难看出, 经过预处理后, 时频图像中基本看不到随机噪声的影响, 有利于低信噪比下的干扰识别。

3 面向小样本的多模态雷达有源欺骗干扰识别方法

原型网络是近年来常用于小样本学习的网络模型, 基本架构如图3所示^[19,20], 其网络结构主要由两部分组成。第1部分为卷积神经网络。在原型网络的结构中, 记 f_θ 为网络的映射函数, f_θ 可将原本的 D 维数据 x 映射到 M 维空间上, 完成对样本的特征提取并得到高维特征向量 z ,

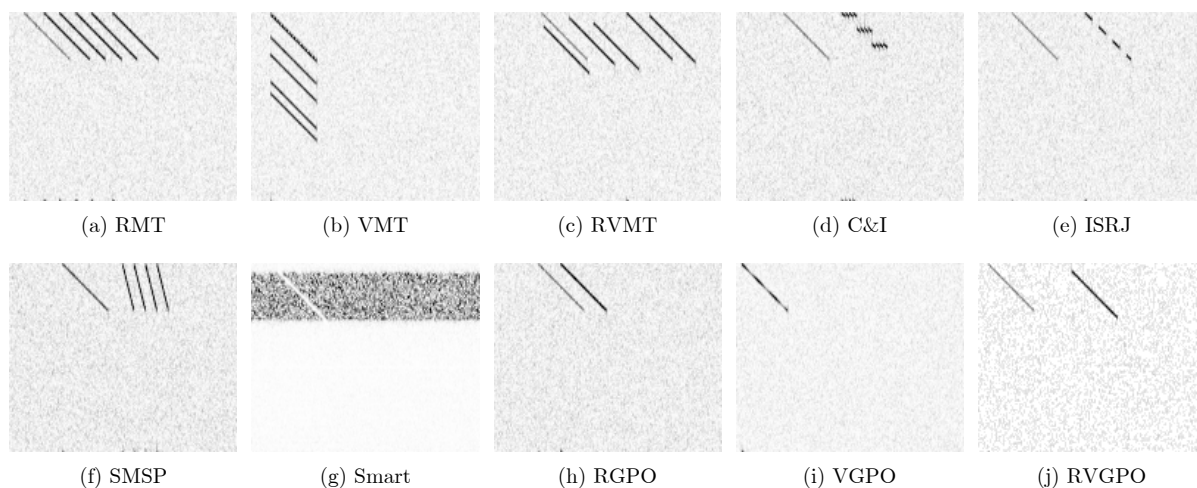


图 1 预处理前的时频图像

Fig. 1 Time-frequency images before preprocessing

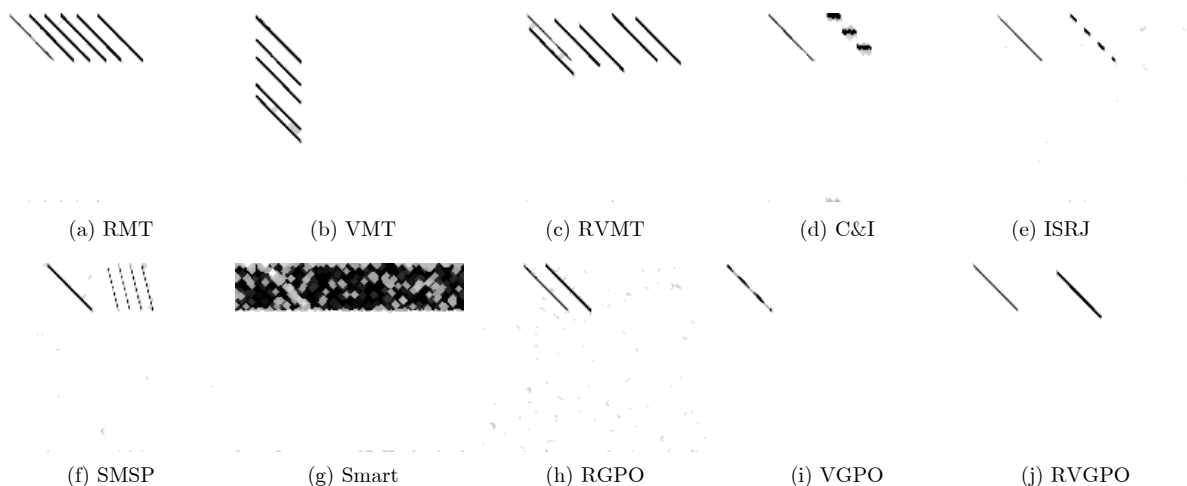


图2 预处理后的时频图像

Fig. 2 Time-frequency images after preprocessing

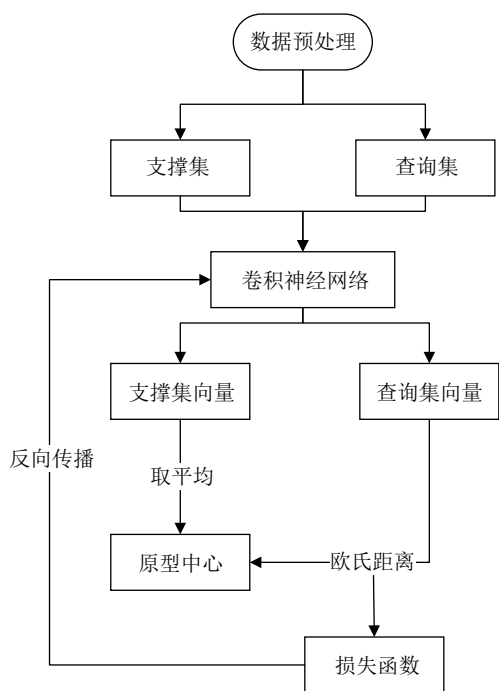


图3 原型网络基本架构图

Fig. 3 Basic architecture of prototype network

$$f_{\theta} : \mathbf{x} \in \mathbb{R}^D \rightarrow \mathbf{z} \in \mathbb{R}^M \quad (7)$$

其中, θ 表示原型网络的参数。

第2部分为原型中心的计算,通过对每类样本的特征向量求和取平均,得到各个类别在特征空间中的原型中心,第 k 类的原型中心 c_k 的计算方式如式(8)所示:

$$c_k = \frac{1}{|S_k|} \sum_{(x_i, y_i) \in S_k} f_{\theta}(x_i) \quad (8)$$

其中, S_k 表示类别为 k 的数据集合, $|S_k|$ 为样本数, x_i 表示第 i 个输入数据, y_i 表示数据标签。迭代更新

此原型中心向量,直至网络学到一个能够使同类样本聚为一簇,不同簇间尽量远离的特征空间。最终,以特征空间中待测样本与各原型中心的距离为分类依据,完成分类任务。

3.1 多模态数据集的构建

一般情况下,神经网络模型仅将输入信息的一种模态信息标签化后进行训练。但不同模态之间往往蕴含着互补的信息,如果能够合理地融合多模态信息,对齐特征,就可以获得一加一大于二的效果,得到信息量丰富的多模态融合特征。因此,可以考虑使用特征参数和时频图像两个模态的信息,再利用特征层融合的方式进行干扰识别。

对于特征参数模态的数据集构建,本文根据雷达有源欺骗干扰的特点,利用干扰信号提取了包括时域矩偏度、时域矩峰度、时域包络起伏度、归一化幅度标准差、频域矩偏度、频域矩峰度、频域包络起伏度、归一化幅度频谱最大值、尺度重心在内的9种共10个特征,构成了特征参数向量^[21],作为一种模态信息。将本文第2节经过预处理的时频图像作为另外一个模态的输入特征。

小样本学习中每类数据的测试样本数量都较少,为了在样本极度匮乏的情况下也能得到一定的训练结果,训练时需进行数据集的扩充。

对于特征向量可以采取高斯随机化样本扩充方法,即对每个特征向量重复多次加入均值为0、方差为 σ^2 的独立同分布高斯噪声,得到充足的特征参数的训练样本,以匹配图像模态的数据量。此外,高斯随机化过程在扩充训练样本空间、防止中心网络过拟合的同时,还可以提高鲁棒性,有利于后续的训练。

对于时频图像,由于随机噪声对于进行预处理

后的时频图像影响较小,无法考虑类似特征向量的随机化扩充方式。而Omniglot数据集^[22]由来自50种不同语言的1623个手写字符构成的,每个字符都有20个不同的笔迹,这就构成了一个样本类别极多,但每种类别的样本数量极少的小样本手写字数据集。字符数据集的识别主要依靠简单的线条特征,与雷达有源欺骗干扰的时频图像有着相似之处,借助该数据集扩充干扰时频图像样本,并与扩充过的特征参数进行匹配训练,以实现小样本条件下的训练效果。

3.2 多模态特征融合网络

本节给出一种基于小样本和多模态特征融合的雷达有源欺骗干扰识别网络,网络结构如图4所示。网络以特征向量和时频图像为输入,首先,根据两种模态的数据的不同格式,分别构建两个卷积神经网络进行特征提取。其次,将不同模态提取到的特征进行特征层融合,对于第*i*个对象,提取出的特征向量数据 x_i^T 和时频图像数据 x_i^P ,并通过网络得到特征参数向量特征和时频图像特征分别记为 $f_T(x_i^T)$ 和 $f_P(x_i^P)$,将两种特征拼接得到融合特征 $f_\phi(x_i^T, x_i^P)$

$$f_\phi(x_i^T, x_i^P) = \text{Concat}(f_T(x_i^T), f_P(x_i^P)) \quad (9)$$

Concat为向量拼接。根据式(9)和式(8)可构建新的原型中心,之后便可以通过计算网络的损失函数,对参数进行优化完成迭代训练。最后,将待识别数据的特征参数向量和时频图像输入网络,根据待识别样本与各原型中心的距离实现干扰识别。由于小样本识别过程中可能会存在信噪比较低的单模态数据,或者单模态失效的数据,为了排除可能存在的“坏数据”的影响,提高低信噪比下的检测概率,在训练过程中需要对传统的欧氏距离进行加权,加权欧氏距离如式(10)所示:

$$d(f_\phi(x), c_k) = \|f_\phi(x) - c_k\|^2 \cdot \left(1 + \sin \frac{z_2 - z_1}{z_2 + z_1}\right),$$

$$z_1 = \|f_P(x) - c_k^1\|^2,$$

$$z_2 = \|f_T(x) - c_k^2\|^2 \quad (10)$$

其中, $\|\cdot\|$ 表示取模运算, c_k^1 和 c_k^2 分别表示原型中的不同模态分量。对基础的欧氏距离进行加权,可以有效改善低信噪比下的单一特征失效引起的混淆。

网络中通过查询集中样本的预测分数 p_i 可表示如下:

$$p_i(Y = y_i|x_i) = \frac{\exp(-d(f_\phi(x), c_k))}{\sum_{k'} \exp(-d(f_\phi(x), c_{k'}))}$$

其中, y_i 表示查询集中第*i*个样本 x_i 的真实标签。将 p_i 和真实标签进行对比,计算损失值并通过反向传播的方式优化损失函数 L 中的参数 θ ,损失函数如下:

$$L(\theta) = \sum_i -\ln(p_i(Y = y_i|x_i))$$

多模态网络结构如图4所示,网络 ϕ_T 和 ϕ_P 分别计算特征参数模态下和时频图像模态下的原型。计算机中的运算大都是基于基础的乘加运算进行的,单个卷积层的时间复杂度计算方法如下:

$$O(C_{in} \cdot K^2 \cdot H \cdot W \cdot C_{out}) \quad (11)$$

其中, C_{in} 表示输入特征图通道数, K 为卷积核的尺寸, H 和 W 分别代表对应输出特征图的尺寸, C_{out} 表示卷积核的数目,即输出的维度。池化层的时间复杂度计算方式为

$$O(C_{in} \cdot H \cdot W) \quad (12)$$

因此,一个网络的整体时间复杂度可表示为

$$O\left(\sum_{l=1}^d (H_l \cdot W_l \cdot K_l^2 \cdot C_{l-1} \cdot C_l)\right) \quad (13)$$

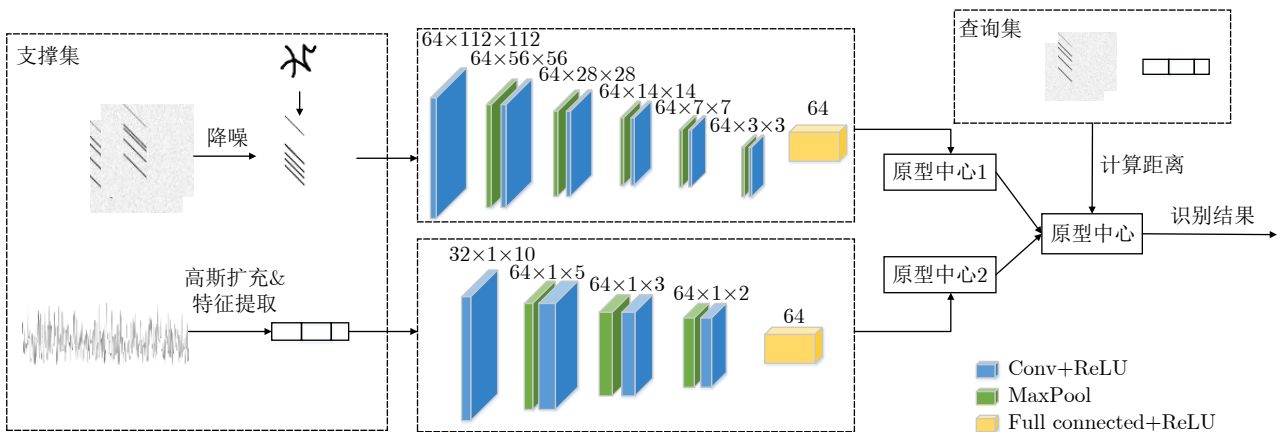


图 4 多模态特征融合网络

Fig. 4 Multimodal feature fusion network

其中, d 为网络的深度, l 表示第 l 个卷积层, C_l 为第 l 个卷积层的输出通道数, 对于第 l 个卷积层而言, C_{l-1} 即为第 l 个卷积层的输入通道数。

为衡量模型的复杂度, 在实际网络中, 根据图4中输入尺寸与各层卷积核大小分别计算网络 ϕ_T , ϕ_P 以及时频图像网络^[23]、特征参数网络^[24]与孪生网络^[25]的浮点运算数(Floating Point Operations, FLOPs)和参数量, 结果如表1所示。

4 仿真实验与分析

针对第2节所述10种雷达有源欺骗干扰, 以式(1)作为接收信号模型, 构建仿真数据集进行算法性能测试。信号基本参数及部分干扰信号核心参数如表2所示。

表1 不同网络的复杂度参数表

Tab. 1 Table of complexity parameters for different networks

网络	FLOPs (G)	Params (M)
网络 ϕ_T	0.000339968	0.041760
网络 ϕ_P	0.165375488	0.186048
时频图像网络 ^[23]	0.216158208	0.186048
特征参数网络 ^[24]	0.000408576	0.041760
孪生网络 ^[25]	3.395630784	138.357544

表2 回波信号与欺骗干扰信号基本参数设置

Tab. 2 Basic parameter setting of echo signal and jamming signal

信号类型	参数	数值
回波与干扰信号	载波	5.5 GHz
	带宽	10 MHz
	采样率	40 MHz
	脉冲宽度	50 μ s
	脉冲重复频率	4000 Hz
	信噪比	-10~10 dB
密集假目标干扰	干信比	3 dB
	假目标数量	3~7
切片重构干扰	矩形脉冲串的个数	3~5
	每一段填充的时隙数	3~5
间歇采样转发干扰	间歇采样脉冲宽度	7~9 μ s
	间歇采样周期	12~15 μ s
频谱弥散干扰	采样倍数	3~5
卷积灵巧噪声干扰	噪声带宽倍数	0.3~0.7
距离拖引干扰	拖引速度	300~600 m/s
速度拖引干扰	拖引加速度	50~200 m/s ²
距离速度联合拖引干扰	拖引速度	300~600 m/s
	拖引加速度	50~200 m/s ²

为拟合小样本场景, 以每种欺骗干扰仅包含20个脉冲信号, 信噪比随机取-10~10 dB, 其他参数如表1所示, 按照3.1节所述构造干扰信号训练集。在训练时, 为提高模型训练能力与泛化能力, 除10种干扰类型外, 引入Omniglot数据集的214种手写字符每类20个样本进行辅助训练, 支持集与查询集样本数均为5, 每次训练10个类, 初始学习率设置为0.001。同时随机生成10种干扰每种干扰500个脉冲信号, 其他参数不变, 构建测试样本集, 对多模态特征融合网络进行测试, 测试结果如图5所示(实验在GPU为NVIDIA GeForce RTX 2060的电脑上运行, 通过MATLAB 2021a编程实现)。

从图5可以观察到, 利用特征融合的原型网络在训练样本较少的情况下, 依旧可以得到比较好的识别效果, 总体识别率达到了97.65%, 实现了小样本下的干扰识别。从图5可以看到针对特征鲜明的干扰, 例如卷积灵巧噪声等, 网络的识别情况较好, 主要的混淆出现在拖引干扰和密集假目标类干扰, 这是由于在拖引的前期, 真假目标还处在同一波门内, 差距较小, 识别的难度高, 容易和其他拖引类混淆, 同时也容易与波门内存在较少假目标的密集假目标类干扰混淆。

4.1 抗噪性分析

为验证所提网络在不同信噪比下的识别性能, 设置信噪比从-15~10 dB, 选取每种干扰20个脉冲样本进行训练, 测试时随机生成10种干扰每种干扰500个脉冲信号。这样, 得到不同网络在不同信噪比下的识别性能如图6所示。

从图6可以观察到, 仅考虑单一模态下的识别, 时频图像模态的识别效果是要优于特征参数模态的, 这说明图像的抗噪能力要强于时域特征。当信噪比较高时, 采用模态融合的方式可以丰富识别特征的信息量, 从而提高总体识别率。同时, 从图6可以看出, 用加权欧氏距离训练的多模态网络在低信噪比下的识别性能要优于传统的欧氏距离。

4.2 小样本性能分析

小样本识别的出现, 最初就是为了解决训练集样本不充分、不全面条件下的识别问题。通过简化网络以及度量学习的方法, 小样本识别可以在较少样本下得到识别结果, 但依旧会在一定程度内受到样本数量的影响。因此, 训练样本数也是衡量小样本识别网络的一个重要指标。

为测试多模态网络能力, 选取信噪比在-10~10 dB下, 样本数量为2, 5, 10, 15, 20的各类干扰信

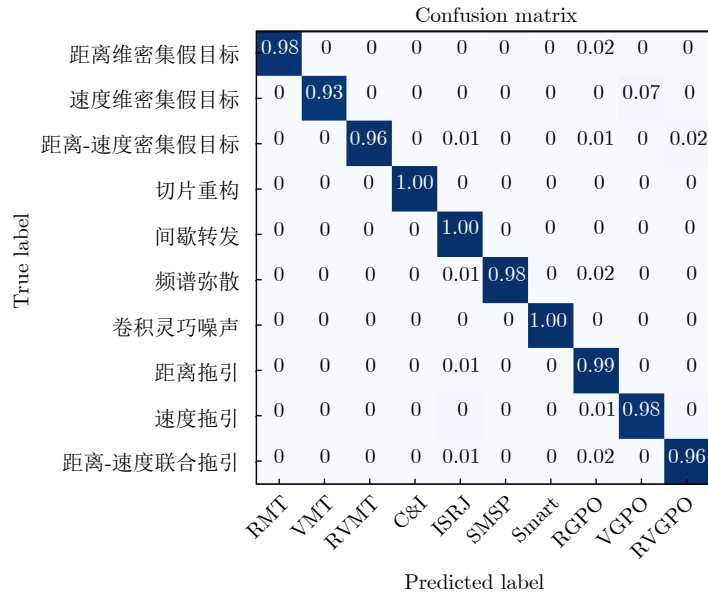


图 5 本文方法的混淆矩阵(平均识别率97.65%)

Fig. 5 Confusion matrix of the proposed method (average recognition rate 97.65%)




图 6 不同网络在不同信噪比下识别性能比较

Fig. 6 Comparison of recognition performance of different networks under different signal-to-noise ratios

号构建训练集，另外选取每类干扰500个随机信噪比的样本构建测试集，分别进行训练并完成测试，测试结果如表3所示。

从表3可以看到，本文所述方法在训练样本较少的情况下依旧可以很好地进行干扰信号的识别，在少量训练样本训练时，借助数据集的扩充，可以

达到80%左右的识别率。固定训练集样本信噪比，测试集信噪比随机时，可以观察到单信噪比训练效果要差于混合信噪比样本训练效果，这主要是由于固定信噪比训练无法捕捉更多的噪声信息，抗噪性能下降，导致总体识别率降低。而当训练样本数大于10后，平均识别率小幅度上升并逐步趋于稳定，能够将识别准确率维持在96%以上。

4.3 泛化能力分析

利用原型网络作为识别网络的优势之一在于，基础的卷积神经网络学习^[26]的是某一类样本的具体特征，而原型网络学习的是样本在特定空间内的表达，这就使得以原型网络作为分类器时能够泛化到训练集中没有出现过的新类。这种泛化能力的优势在于，训练好的网络参数不再受制于特定场景的使用，在其他场景下依赖同场景构建的干扰原型也能进行有效的识别，此外在提供干扰原型时，还可以对未训练干扰类型进行有效识别，更适应于复杂多变的真实场景。

表 3 不同训练样本数下识别性能比较(%)

Tab. 3 Comparison of recognition performance under different numbers of training samples (%)

训练信噪比	2个训练样本	5个训练样本	10个训练样本	15个训练样本	20个训练样本
-10 dB	75.02	92.12	93.46	92.23	92.42
-5 dB	89.14	91.10	91.29	93.24	93.12
0 dB	86.11	92.18	92.29	94.89	93.27
5 dB	84.74	92.83	94.79	89.05	94.97
10 dB	83.17	87.73	87.85	88.41	90.67
随机信噪比	85.18	93.95	96.25	97.56	97.64

前一部分的网络训练及测试所用数据主要来自软件仿真，训练与测试的数据为同源数据。为了测试网络的泛化能力，利用干扰模拟器重新采集包括距离滞后密集假目标干扰、距离超前密集假目标干扰、切片重构干扰、间歇采样转发干扰、距离拖引干扰、速度拖引干扰、距离-速度联合拖引干扰在内的7种干扰信号，干扰模拟器及控制平台如图7所示。

对于干扰模拟器采集的7种干扰信号，随机选取每种类型的干扰干扰比为5 dB的5个脉冲信号用以构建原型，另外选取每类200个参数随机的信号构建测试集，利用4.1节中不在雷达模拟器干扰类别的4种干扰，即速度维密集假目标干扰、距离-速度联合密集假目标干扰、频谱弥散、卷积调制灵巧

噪声干扰，进行训练。图8(a)为孪生网络^[25]的测试结果，图8(b)为本文网络未引入Omniglot数据集的测试结果，图8(c)为本文网络引入Omniglot数据集的测试结果。


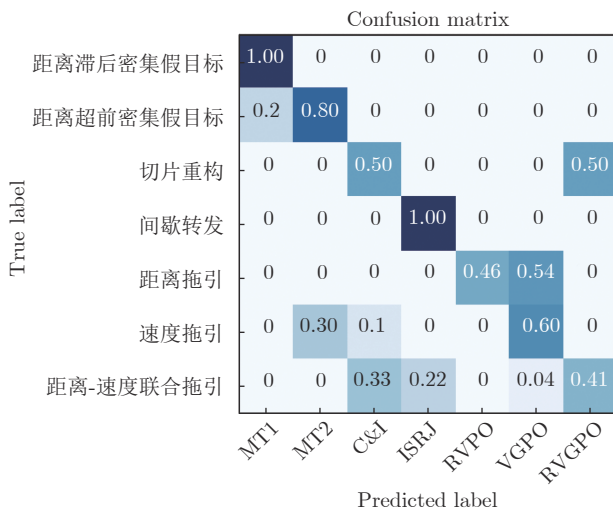



图 7 干扰信号数据获取平台


Fig. 7 Interference signal data acquisition platform



(a) 孪生网络的测试结果
(a) Test results of siamese network



(b) 本文网络未引入Omniglot数据集的测试结果
(b) Test results of introducing the omniglot dataset without the proposed network



(c) 本文网络引入Omniglot数据集的测试结果
(c) Test results of the proposed network into introducing the omniglot dataset

图 8 泛化能力测试结果

Fig. 8 Generalization ability test results

从图8(a)和图8(b)可以看出：对于模拟器产生的7种干扰信号，本文所提网络相比孪生网络能够获得更高的平均识别准确率。对比图8(b)和图8(c)可知，引入Omniglot数据集后，网络的泛化能力有着明显的增强，对于多种干扰表现良好，7种干扰的平均识别准确率优于92%。而对于拖引类干扰，模拟器产生的数据由于模拟器件的使用会产生一定的谐波，这对干扰识别会产生一定的影响，但从总体识别结果来看多模态网络还是得到了比较不错的识别效果，这也从一定程度上证明了本章所提网络的泛化能力。

5 结语

针对一般的雷达欺骗干扰识别方法依赖完备的样本集，无法对有限小样本下的干扰完成检测的问题，本文提出了一种基于小样本的多模态原型网络。通过迁移Omniglot数据集扩充预处理后的时频图像数据集，并融合特征参数与时频图像两个模态的特征，实现特征互补，最后以原型网络训练多模态特征，实现了基于小样本的多模态雷达有源欺骗干扰识别。仿真结果表明，本文所提方法能够在训练样本有限的情况下将不同类型干扰信号总体识别率提升至97%以上，且在泛化能力上表现良好；时频图像的降噪处理和多模态特征的融合，使得所提网络在低信噪比条件下也有良好的识别性能。

参 考 文 献

- [1] KWAK C M. Application of DRFM in ECM for pulse type radar[C]. 2009 34th International Conference on Infrared, Millimeter, and Terahertz Waves, Busan, Korea (South), 2009: 1–2. doi: [10.1109/ICIMW.2009.5324673](https://doi.org/10.1109/ICIMW.2009.5324673).
- [2] ZHANG Haoyu, YU Lei, CHEN Yushi, *et al.* Fast complex-valued CNN for radar jamming signal recognition[J]. *Remote Sensing*, 2021, 13(15): 2867. doi: [10.3390/rs13152867](https://doi.org/10.3390/rs13152867).
- [3] 陈思伟, 崔兴超, 李铭典, 等. 基于深度CNN模型的SAR图像有源干扰类型识别方法[J]. *雷达学报*, 2022, 11(5): 897–908. doi: [10.12000/JR22143](https://doi.org/10.12000/JR22143).
CHEN Siwei, CUI Xingchao, LI Mingdian, *et al.* SAR image active jamming type recognition based on deep CNN model[J]. *Journal of Radars*, 2022, 11(5): 897–908. doi: [10.12000/JR22143](https://doi.org/10.12000/JR22143).
- [4] MENDOZA A, SOTO A, and FLORES B C. Classification of radar jammer FM signals using a neural network[C]. SPIE 10188, Radar Sensor Technology XXI, Anaheim, USA, 2017: 101881G. doi: [10.1117/12.2262059](https://doi.org/10.1117/12.2262059).
- [5] WU Zhilu, ZHAO Yanlong, YIN Zhengdong, *et al.* Jamming signals classification using convolutional neural network[C]. 2017 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT), Bilbao, Spain, 2017: 62–67. doi: [10.1109/ISSPIT.2017.8388320](https://doi.org/10.1109/ISSPIT.2017.8388320).
- [6] ZHAO Qingyuan, LIU Yang, CAI Linjie, *et al.* Research on electronic jamming identification based on CNN[C]. 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP), Chongqing, China, 2019: 1–5. doi: [10.1109/ICSIDP47821.2019.9172911](https://doi.org/10.1109/ICSIDP47821.2019.9172911).
- [7] LIU Qiang and ZHANG Wei. Deep learning and recognition of radar jamming based on CNN[C]. 2019 12th International Symposium on Computational Intelligence and Design (ISCID), Hangzhou, China, 2019: 208–212. doi: [10.1109/ISCID.2019.00054](https://doi.org/10.1109/ISCID.2019.00054).
- [8] HOWARD J and RUDER S. Universal language model fine-tuning for text classification[C]. The 56th Annual Meeting of the Association for Computational Linguistics, Melbourne, Australia, 2018: 328–339. doi: [10.18653/v1/P18-1031](https://doi.org/10.18653/v1/P18-1031).
- [9] DING Kaize, WANG Jianling, LI Jundong, *et al.* Graph prototypical networks for few-shot learning on attributed networks[C]. The 29th ACM International Conference on Information & Knowledge Management, Online, 2020: 295–304. doi: [10.1145/3340531.3411922](https://doi.org/10.1145/3340531.3411922).
- [10] CHOPRA S, HADSELL R, and LECUN Y. Learning a similarity metric discriminatively, with application to face verification[C]. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, USA, 2005: 539–546. doi: [10.1109/CVPR.2005.202](https://doi.org/10.1109/CVPR.2005.202).
- [11] SHAO Guangqing, CHEN Yushi, and WEI Yinsheng. Convolutional neural network-based radar jamming signal classification with sufficient and limited samples[J]. *IEEE Access*, 2020, 8: 80588–80598. doi: [10.1109/ACCESS.2020.2990629](https://doi.org/10.1109/ACCESS.2020.2990629).
- [12] 陈泽伟, 严远鹏. 基于改进DCGAN的毫米波雷达相互干扰时频图像生成研究——以生成样本对CNN干扰抑制模型性能影响为例[J]. *现代信息科技*, 2022, 6(13): 55–61. doi: [10.19850/j.cnki.2096-4706.2022.013.014](https://doi.org/10.19850/j.cnki.2096-4706.2022.013.014).
CHEN Zewei and YAN Yuanpeng. Research on generation of MMW radar mutual interference time-frequency image based on improved DCGAN—a case of performance effect of the generated samples on the CNN interference suppression model[J]. *Modern Information Technology*, 2022, 6(13): 55–61. doi: [10.19850/j.cnki.2096-4706.2022.013.014](https://doi.org/10.19850/j.cnki.2096-4706.2022.013.014).
- [13] KOCH G, ZEMEL R, and SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition[C]. The 32nd International Conference on Machine Learning, Lille, France, 2015: 1–8.
- [14] SNELL J, SWERSKY K, and ZEMEL R S. Prototypical networks for few-shot learning[C]. 31st Conference on Neural Information Processing Systems, Long Beach, USA,

- 2017: 4080–4090.
- [15] LU Yunlong and LI Siyu. CFAR detection of DRFM deception jamming based on singular spectrum analysis[C]. 2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), Xiamen, China, 2017: 1–6. doi: [10.1109/ICSPCC.2017.8242381](https://doi.org/10.1109/ICSPCC.2017.8242381).
- [16] 定少浒, 汤建龙. 基于SSA的DRFM速度欺骗干扰识别[J]. 雷达科学与技术, 2020, 18(1): 44–50. doi: [10.3969/j.issn.1672-2337.2020.01.008](https://doi.org/10.3969/j.issn.1672-2337.2020.01.008).
DING Shaohu and TANG Jianlong. DRFM velocity deception jamming recognition based on singular spectrum analysis[J]. *Radar Science and Technology*, 2020, 18(1): 44–50. doi: [10.3969/j.issn.1672-2337.2020.01.008](https://doi.org/10.3969/j.issn.1672-2337.2020.01.008).
- [17] LV Qinzhe, QUAN Yinghui, FENG Wei, *et al.* Radar deception jamming recognition based on weighted ensemble CNN with transfer learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 5107511. doi: [10.1109/TGRS.2021.3129645](https://doi.org/10.1109/TGRS.2021.3129645).
- [18] JAMIL N, SEMBOK T M T, and BAKAR Z. A. Noise removal and enhancement of binary images using morphological operations[C]. 2008 International Symposium on Information Technology, Kuala Lumpur, Malaysia, 2008: 1–6. doi: [10.1109/ITSIM.2008.4631954](https://doi.org/10.1109/ITSIM.2008.4631954).
- [19] XI Bobo, LI Jiaojiao, LI Yunsong, *et al.* Deep prototypical networks with hybrid residual attention for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 3683–3700. doi: [10.1109/JSTARS.2020.3004973](https://doi.org/10.1109/JSTARS.2020.3004973).
- [20] 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. doi: [10.12263/DZXB.20210932](https://doi.org/10.12263/DZXB.20210932).
LI Qiang, ZHANG Wei, JIN Qiuyuan, *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. doi: [10.12263/DZXB.20210932](https://doi.org/10.12263/DZXB.20210932).
- [21] GAO Meng, LI Hongtao, JIAO Bixuan, *et al.* Simulation research on classification and identification of typical active jamming against LFM radar[C]. Proceedings of SPIE 11384 Eleventh International Conference on Signal Processing Systems, Nanjing, China, 2019: 113840T. doi: [10.1117/12.2559607](https://doi.org/10.1117/12.2559607).
- [22] LAKE B M, SALAKHUTDINOV R, and TENENBAUM J B. The Omniglot challenge: A 3-year progress report[J]. *Current Opinion in Behavioral Sciences*, 2019, 29: 97–104. doi: [10.1016/j.cobeha.2019.04.007](https://doi.org/10.1016/j.cobeha.2019.04.007).
- [23] WANG Jingyi, DONG Wenhao, and SONG Zhiyong. Radar active jamming recognition based on time-frequency image classification[C]. 2021 5th International Conference on Electronic Information Technology and Computer Engineering, Xiamen, China, 2021: 449–454. doi: [10.1145/3501409.3502153](https://doi.org/10.1145/3501409.3502153).
- [24] TIAN Xinyi, CHEN Baixiao, and ZHANG Zhaoming. Multiresolution jamming recognition with few-shot learning[C]. 2021 CIE International Conference on Radar, Haikou, China, 2021: 2267–2271. doi: [10.1109/Radar53847.2021.10027919](https://doi.org/10.1109/Radar53847.2021.10027919).
- [25] 梁先明. 一种优化孪生网络的小样本辐射源个体识别方法[J]. 电讯技术, 2022, 62(6): 695–701. doi: [10.3969/j.issn.1001-893x.2022.06.001](https://doi.org/10.3969/j.issn.1001-893x.2022.06.001).
LIANG Xianming. An emitter individual identification method for small samples based on optimized siamese networks[J]. *Telecommunication Engineering*, 2022, 62(6): 695–701. doi: [10.3969/j.issn.1001-893x.2022.06.001](https://doi.org/10.3969/j.issn.1001-893x.2022.06.001).
- [26] GU Jiuxiang, WANG Zhenhua, KUEN J, *et al.* Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, 77: 354–377. doi: [10.1016/j.patcog.2017.10.013](https://doi.org/10.1016/j.patcog.2017.10.013).

作者简介

张顺生, 博士, 研究员, 主要研究方向为新体制雷达探测与成像、人工智能技术在雷达、电子战中的应用等。

陈爽, 硕士生, 主要研究方向为雷达有源欺骗干扰识别。

陈晓莹, 博士生, 主要研究方向为雷达信号处理、雷达抗干扰和认知雷达。

刘莹, 博士, 教授, 主要研究方向为数据挖掘、人工智能和高性能计算等。

王文钦, 博士, 教授, 主要研究方向为新体制雷达、雷达信号处理和电子对抗技术。

(责任编辑: 高山流水)