

空地协同场景下通信干扰智能识别方法

刘明骞^{*①} 高晓腾^② 李明^③ 朱守中^④

^①(西安电子科技大学综合业务网理论及关键技术国家重点实验室 西安 710071)

^②(中国电子科技集团有限公司第五十四研究所 石家庄 050050)

^③(中国电子信息产业集团有限公司国营第七二二厂 桂林 541001)

^④(长沙无源定位工程技术研究院 长沙 410008)

摘要: 针对现有通信干扰智能识别方法在小样本条件下识别精度低、网络模型欠拟合的问题,并形成通信干扰识别的空中与地面布设能力,该文提出一种空地协同场景下基于孪生网络的通信干扰智能识别方法。首先在空中无人机与地面设备之间构建空地协同的通信干扰认知架构,并通过提取所接收的通信干扰信号的时频图、分数阶傅里叶变换和星座图,对通信干扰信号进行智能表征,以作为网络的输入。然后搭建基于密集连接网络的网络结构,并设计双输入权值共享的孪生网络。最后,利用随机样本对孪生网络进行训练,并通过孪生单边网络构建基准通信干扰类型特征库进而实现通信干扰的智能识别。该方法通过度量两个样本之间的特征距离来判断样本的相似性,并通过相似度量扩大了训练样本数量并训练了孪生网络模型。仿真结果表明,所提方法不但在较小数据集的条件下可有效地实现通信干扰的智能识别,而且相比现有的智能识别方法,所提方法的识别性能显著提升。

关键词: 通信干扰; 空地协同; 孪生网络; 智能识别; 小样本学习

中图分类号: TN974

文献标识码: A

文章编号: 1009-5896(2022)03-0825-10

DOI: [10.11999/JEIT211260](https://doi.org/10.11999/JEIT211260)

Communication Interference Intelligent Recognition in the Air-to-ground Collaboration Scenario

LIU Mingqian^① GAO Xiaoteng^② LI Ming^③ ZHU Shouzhong^④

^①(State Key Laboratory of Integrated Services Networks, Xidian University, Xi'an 710071, China)

^②(The 54th Research Institute of China Electronics Technology Group Corporation,
Shijiazhuang 050050, China)

^③(The State 722 Factory, China Electronics Corporation, Guilin 541001, China)

^④(Changsha Institute of Passive Location Engineering Technology, Changsha 410008, China)

Abstract: In view of the problems that the existing communication interference intelligent recognition methods have low recognition accuracy under the small samples condition and the under-fitting of the network model, an intelligent communication interference recognition method based on twin network in the air-to-ground collaboration scenario is proposed to form the air and ground layout ability. Firstly, the time-frequency diagram, fractional Fourier transform and constellation diagram of the received communication interference signals are extracted as network inputs in the air-to-ground collaboration communication interference cognitive architecture between unmanned air vehicles and ground equipment. Secondly, the network structure based on densely connected convolutional networks is built, and the twin network with dual input weight sharing is designed. Finally, the twin network is trained with random samples, and the benchmark communication interference type feature library is constructed through the twin unilateral network, so as to realize the communication interference intelligent identification. The proposed method evaluates the similarity of samples

收稿日期: 2021-11-12; 改回日期: 2022-02-19; 网络出版: 2022-03-01

*通信作者: 刘明骞 mqliu@mail.xidian.edu.cn

基金项目: 国家自然科学基金(62071364), 航空科学基金(2020Z073081001), 中央高校基本科研业务费专项资金(JB210104), 高等学校学科创新引智计划(B08038)

Foundation Items: The National Natural Science Foundation of China (62071364), The Aeronautical Science Foundation of China (2020Z073081001), The Fundamental Research Funds for the Central Universities (JB210104), The 111 Project (B08038)

by measuring the feature distance between two samples, and expands the number of training samples and trains the Siamese network model through the similarity measurement. Simulation results show that the proposed method can effectively realize the communication interference recognition under the support of small data sets, and the recognition performance is significantly improved compared with the existing intelligent recognition methods.

Key words: Communication interference; Air-to-ground collaboration; Twin network; Intelligent recognition; Few-shot learning

1 引言

通信干扰是一种能够阻碍无线通信系统进行信息传输的电子干扰。在无线通信系统面临日益复杂的电磁环境下,通信设备遭受多类型通信干扰的影响^[1]。为了保障信息的可靠传输,各种通信抗干扰技术应运而生,尤其是对通信有效性要求更高的军事通信。然而在实际通信系统中干扰类型复杂多样,一种抗干扰策略往往只对特定干扰类型有效,基于接收机复杂度考虑,同时采取所有的抗干扰措施比较困难,并且抗干扰策略会针对不同的通信干扰类型^[2]。因此,快速精准的干扰类型识别是实施高效通信抗干扰技术的前提与基础,对提升通信系统抗干扰性能具有重要意义。

传统的通信干扰识别技术的研究主要集中在特征参数的选取和分类器的设计。文献^[3]提出一种基于Hilbert变换的未知干扰自适应识别方法,该方法分析了干扰信号在Hilbert空间的特征,建立了干扰信号特征空间,并利用投影定理对未知干扰进行拟合,最后通过概率神经网络进行干扰识别。文献^[4]提出了一种基于奇异值分解的干扰识别方法,该方法通过对干扰信号进行奇异值分解,并利用差分运算得到干扰特征,采样神经网络分类器完成干扰识别。这些方法通常采用人工提取特征,并通过设定判决门限或利用浅层学习进行识别。虽然上述方法在一定程度上解决了通信干扰识别问题,但有用信息损失较多。深度学习可以自动提取高维特征,能够充分挖掘信号更深层次的信息,避免过度依赖专家特征。近年来,已有学者将深度学习与通信干扰识别相结合,提出了基于深度学习的通信干扰智能识别方法。文献^[5]提出了一种基于卷积神经网络的分类器和基于长短时记忆的调制分类方法,并对其提取的无线电特征进行了可视化处理。文献^[6]研究了基于深度学习网络的通信干扰识别方法,通过利用实数卷积神经网络、复数卷积神经网络、实数残差网络和复数残差网络来设计干扰识别的方法。所设计分类方法具有良好的识别精度,且具有一定的迁移能力,其中复数残差网络性能最优。相对于传统方法,基于深度学习的方法能够自动提取特征,

具有更高的准确率,但是它们均需要足够多的样本来训练网络模型。而在实际工程应用中,复杂的电磁环境往往导致无法获得足够的干扰信号样本,在样本缺少的条件下,上述网络模型将出现过拟合,识别性能将严重退化。

小样本学习能够快速地从少量的样本中学习到的关键的知识,避免大量样本的采集以及长时间的模型训练,可以有效地解决样本稀缺情景下深度神经网络模型失配的问题。目前,基于小样本学习的识别算法主要集中于图像识别方面。文献^[7]提出了一种通过对抗过程估计生成模型的新框架,可以同时训练捕获数据分布的生成模型和估计小样本数据分布的判别模型。文献^[8]提出了一种利用孪生网络^[9,10]进行单样本学习的方法,使用两个卷积神经网络提取输入图像特征,将其映射到1维向量,并通过距离函数判断样本对之间的距离,选取距离最小的样本标签作为分类结果。文献^[11]提出了一种匹配网络,利用长短期记忆网络将样本映射到低维特征空间中,再计算与有标签样本之间的相似度,通过核密度估计函数得到输出标签。然而,鲜有文献将小样本学习应用到通信干扰识别领域。

针对小样本条件下基于深度神经网络的通信干扰识别性能差、模型失配的问题,本文在空中无人机与地面设备之间构建空地协同的通信干扰侦收架构下,提出一种基于小样本学习的通信干扰智能识别方法。通过通信干扰的智能表征及基于密集连接网络(Dense connected convolutional Networks, DenseNet)结构的构建,设计双输入权值共享的孪生网络,从而自适应地提取了通信干扰的深层特征,并实现了通信干扰类型的智能识别。实验结果表明,在小样本情况下,所提的空地协同的通信干扰识别方法可以获得更好的性能。

2 空地协同的通信干扰认知系统模型

无人机具备实现灵活、感知能力强和决策周期短、全寿命成本低的优点,可以作为空中感知节点与地面设备构成协同感知、认知等环节,共同完成通信干扰认知任务。无人机蜂群需要侦收远区的通信干扰数据,但由于地形复杂,地面装甲车并不能

赶赴该区域进行通信干扰数据的侦收。因此，需要对该无人机蜂群进行重新组网，该系统模型如图1所示。其中多架无人机位于山区上方进行“空-空地”通信链路，其他无人机对远区的干扰数据进行分布式传输至中继无人机。最后，这些中继无人机将蜂群侦收到的通信干扰数据回传至地面装甲车，在装甲车上进行数据信号级融合，并进行通信干扰的认知。

通信干扰样本数据库由压制式干扰样本和欺骗式干扰样本组成。其中，压制式干扰使用更为广泛，主要通过降低信噪比提高对方通信系统的误码率。典型的压制式干扰类型为单音干扰、多音干扰、噪声调频干扰、部分频带噪声干扰、线性扫频干扰等。

单音干扰为最简单的干扰形式，由单一的频率分量构成，其表达式为

$$J(t) = A \exp(j(2\pi f_c t + \varphi)) \quad (1)$$

其中， A 为干扰信号幅度， f_c 为载频， φ 为初始相位。

多音干扰由多个单音干扰组成，可以表示为

$$J(t) = \sum_{m=1}^M A_m \exp(j(2\pi f_m t + \varphi_m)) \quad (2)$$

其中， A_m 、 f_m 和 φ_m 分别为组成多音干扰的第 m 个单音干扰的幅度、载频与初始相位。

部分频带噪声干扰使噪声能量分布在一定的带宽之内，可以表示为

$$J(t) = U_n(t) \exp(j(2\pi f_c t + \varphi)) \quad (3)$$

其中， $U_n(t)$ 为均值为零，方差为 σ_n^2 的白噪声， f_c 为载频， φ 为初始相位。

噪声调频干扰幅度保持不变，其频率受调制噪声影响而变化，可以表示为

$$J(t) = A \exp\left(j\left(2\pi f_c t + k_{fm} \int_0^t \xi(t') dt'\right)\right) \quad (4)$$

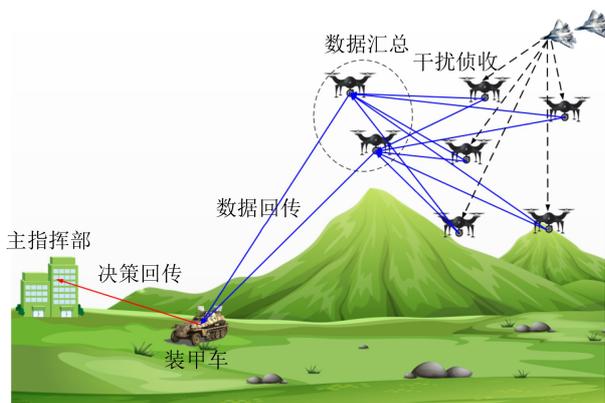


图1 空地协同的通信干扰认知系统模型

其中， A 为干扰幅度， f_c 为载频， k_{fm} 为调频系数， $\xi(t)$ 为调制高斯噪声，其均值为零，方差为 σ_n^2 。

线性调频(Linear Frequency Modulation, LFM)干扰的频率和时间呈线性关系，在某一瞬间只包含单一频率，在一定的时间范围内具有宽带扫描的特性，可以表示为

$$J(t) = A \exp[j(2\pi f_c t + \pi k t^2 + \varphi_0)] \quad (5)$$

其中， A 为干扰幅度， f_c 为干扰载频， k 为调制斜率， φ_0 为初始相位。

欺骗式干扰通过模仿对方使用的无线信号使其不能提取有效信息。对于直扩通信系统，当干扰信号与有用信号具有一致的扩频码和载频时，干扰信号与有用信号将被一同解扩与解调，严重影响通信系统的正常工作。但是在实际中，扩频码的获取和信号精准同步具有很大的难度。当干扰信号使用与真实扩频码有一定相关性的伪随机码(Pseudo-Noise code, PN)，在同步较好时也能达到很好的干扰效果，这种干扰称为随机二元码调制干扰，也称BPSK干扰，可以表示为

$$J(t) = s(t) \cos(2\pi f_c t + \varphi_0) \quad (6)$$

其中， $s(t) = A \sum_n a_n g(t - nT_s)$ ， A 为干扰幅度， a_n 为 -1 或 $+1$ ， $g(t)$ 为矩形脉冲其脉宽为 T_s ， f_c 为BPSK干扰的载频， φ_0 为初始相位。根据码元速率的大小可以将其分为窄带和宽带两种干扰，当码元速率 T_s 小于真实码元速率时为窄带BPSK干扰(BPSK_NBJ)，当 T_s 大于真实码元速率时为宽带BPSK干扰(BPSK_WBJ)。

3 通信干扰的智能表征

不同类型的通信干扰信号在小样条件下时间序列差异性很小，若直接输入干扰信号序列对网络进行训练，容易造成网络过拟合现象。因此，本文对通信干扰信号进行智能表征，以凸显多类型通信干扰之间的区别，加速网络收敛以提高干扰识别性能。本文主要以通信干扰信号的时频图^[12]、分数阶傅里叶变换^[13]和星座图作为智能表征，并将其3通道数据作为网络的输入。其中，星座图主要用于区分欺骗式干扰和压制式干扰，分数阶傅里叶变换主要用于区分线性调频干扰，时频图主要用于区分压制式干扰。下面分别介绍这三种智能表征方法。

魏格纳-威利分布(Wegener-Ville Distribution, WVD)是一种Cohen类双线性变换，能够在时频域上对信号的能量分布进行描述，其表达式为

$$W_x(t, f) = \int_{-\infty}^{+\infty} J\left(t + \frac{\tau}{2}\right) J^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f \tau} d\tau \quad (7)$$

其中, $J(t)$ 为干扰信号, $J^*(t)$ 为干扰信号 $J(t)$ 的共轭, t 和 f 分别为WVD对应的时间和频率, τ 为积分变量。

由于WVD属于2次型非线性变换, 会产生严重的交叉项干扰。通过加窗的方法可对交叉项干扰进行抑制。在式(7)中添加时域窗函数, 对频域进行平滑处理, 以达到抑制交叉项的效果, 得到伪WVD分布为

$$P_{W_x}(t, f) = \int_{-\infty}^{+\infty} h(\tau) J\left(t + \frac{\tau}{2}\right) J^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau \quad (8)$$

其中, $P_{W_x}(t, f)$ 为干扰信号 $J(t)$ 的PWVD, $h(\tau)$ 为时间窗函数。该处理虽然减小了频域的交叉项干扰, 但是时域仍然存在严重的交叉项干扰, 因此, 继续对其进行优化, 在PWVD的基础上, 进一步在时域上进行平滑处理得到平滑伪魏格纳-威利分布(Smooth Pseudo Wegener-Ville Distribution, SPWVD), 它可以表示为

$$S_{PW_J}(t, f) = \int_{-\infty}^{+\infty} h(\tau) \cdot \left[\int_{-\infty}^{+\infty} g(u - \tau) J\left(t + \frac{\tau}{2}\right) \cdot J^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} du \right] d\tau \quad (9)$$

其中, $S_{PW_J}(t, f)$ 为干扰信号 $J(t)$ 的SPWVD, $g(u - \tau)$ 为频率窗函数。

单音干扰的SPWVD如图2(a)所示, 由一条水平线构成, 干扰频率不随时间变化。多音干扰如图2(b)所示由多条水平线构成。噪声调频干扰如图2(c)所示, 占据了1 MHz带宽, 在带宽内能量分布较为杂乱。线性调频干扰如图2(d)所示, 其频率随着时间线性变化, 在时频图中呈一条斜线, 斜线的倾斜度代表LFM调频斜率, LFM干扰在某一时刻为单一频率干扰, 从整个时间段上观察则为宽带信号。

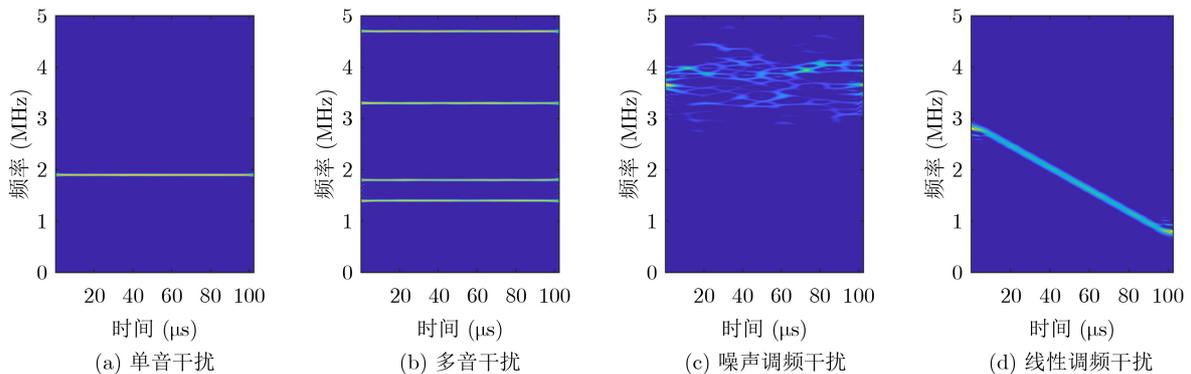


图2 通信干扰信号的时频图

分数阶傅里叶变换(Fractional Fourier Transform, FRFT) 将信号在时频域上的能量分布映射为FRFT域上的分布, FRFT平面坐标轴由时频平面逆时针旋转一定角度得到。它可以从处于时域和频域之间的FRFT域表征信号, 融合了信号的时频特性。通信干扰信号 $J(t)$ 的FRFT表达式为

$$X_p(u) = F^p [J](u) = \int_{-\infty}^{+\infty} J(t) K_p(t, u) dt \quad (10)$$

其中, F^p 是分数阶傅里叶变换算子, 核函数 $K_p(t, u)$ 为

$$K_p(t, u) = \begin{cases} A_\alpha e^{j(t^2 \cot \alpha/2 - ut \csc \alpha + u^2 \cot \alpha/2)}, & \alpha \neq n\pi \\ \delta(t - u), & \alpha = 2n\pi \\ \delta(t + u), & \alpha = (2n + 1)\pi \end{cases} \quad (11)$$

其中, $A_\alpha = \sqrt{(1 - j \cot \alpha)/2\pi}$, $\alpha = p\pi/2$ 代表时频平面的旋转角度。可见FRFT是信号在一组正交的Chirp基上的展开, 线性扫频干扰信号的某一阶次的FRFT是一个 δ 函数。借助FRFT对线性扫频信号的聚焦性可以很好地区分线性扫频干扰信号与其他干扰信号。在智能表征干扰信号时, 通过不断调整 p 值的大小得到干扰信号的分数阶变换矩阵

$$\mathbf{X}(u) = [X_{p_1}(u) \cdots X_{p_i}(u) \cdots X_{p_N}(u)] \quad (12)$$

其中, $X_{p_i}(u)$ 表示阶数为 p_i 的分数阶傅里叶变换。

线性调频干扰的FRFT如图3(a)所示, 可见在 p 为0.31处时干扰信号能量聚集成一个很高的峰值, 而其他压制式干扰如部分频带噪声干扰的FRFT如图3(b)所示, 能量分布较为杂散。因此, FRFT可以区分线性调频干扰与其他干扰。

星座图蕴含着丰富的调制信息, 主要用于区分压制式干扰信号与欺骗式干扰信号。由于随机二进制码干扰采用BPSK的调制方式, 其星座图由圆周上相差 180° 的两个点组成, 由于噪声的影响, 信号会

分在两个理想点的周围，BPSK_NBJ星座图如图4(a)所示，BPSK_WBJ星座图与BPSK_NBJ星座图区别不大，单音干扰的星座图呈现环状如图4(b)所示，信号点匀称地散布在单位圆附近，多音干扰和部分频带噪声干扰的星座图分布较为杂乱如图4(c)、图4(d)所示，其信号点较为杂乱地分布在圆心附近。可见，欺骗式干扰可以通过星座图与压制式干扰进行区分。

根据以上的表征方法，可将通信干扰信号智能表征为

$$\nu = [S_{PW_J}(t, f), X_J(u), S_J] \quad (13)$$

其中， $S_{PW_J}(t, f)$ 为干扰的SPWVD变换， $X_J(u)$ 为干扰的分数阶傅里叶变换， S_J 为干扰信号的星座图。

4 通信干扰的智能识别

4.1 基于DenseNet的子网络结构

残差网络(Residual Networks, ResNet)通过在多层网络层之间建立一条连接通道，让多个有参层学习输入和输出之间的残差表示获得更好的性能。DenseNet则摆脱了通过加宽加深网络的定式思维，利用特征复用和配置旁路很大程度上压缩了网络参数规模，减轻了梯度消失现象，使得该网络更容易收敛，且具有很好的正则效果和抗过拟合能力。

DenseNet主体由密集块(DenseBlock)和过渡层(Transition)组成，假设 x_i 是密集块中第 i 层的输出， $H_i(\cdot)$ 为第 i 层的非线性变换函数，由批归一化(Batch Normalization, BN)，激活函数ReLU，以

及卷积层Conv组成。密集块内部不同网络层采用密集连接的形式，即第 i 层的输入为第 $i-1$ 层输出和之间所有层输出的堆叠，则密集块中第 i 层的输出 x_i 可以表示为

$$x_i = H_i([x_0, x_1, \dots, x_{i-1}]) \quad (14)$$

其中， $[\cdot]$ 表示智能表征的拼接。 $H_i(\cdot)$ 的输出的通道数为定值 k ，则第 i 层网络将会有 $k_0 + k \times (i-1)$ 个智能表征， k_0 为输入层通道数， k 也被称作生长率(Growth rate)，一般取值较小。DenseNet这种密集连接的方式不仅减少了参数量，还使得每一层都可以从损失函数和输入获得梯度信息，改善了网络的信息流动，使网络获得了性能提升。

过渡层用于连接两个密集块，其作用主要是调整智能表征的尺寸，一般由 1×1 卷积层和步长为2的池化层组成。过渡层输出的智能表征数量为 θm ，其中 m 为过渡层前一个密集块输出的智能表征个数， $0 < \theta \leq 1$ 为压缩因子，当 θ 小于1时可以起到减少网络参数和特征融合的作用。

借鉴DenseNet密集块的思想，本文设计了包括多个密集块和过渡层的用于通信干扰识别任务的网络模型，其具体结构如图5所示，网络的输入为 $128 \times 128 \times 3$ 的通信干扰信号智能表征，该表征首先通过1个步长为2的 7×7 卷积层，1个步长为2的 4×4 最大池化层，随后进入第1个密集块，密集块内使用步长为1的 3×3 卷积层以保持智能表征尺寸不变，密集块增长率大小为8，即卷积层使用的卷积

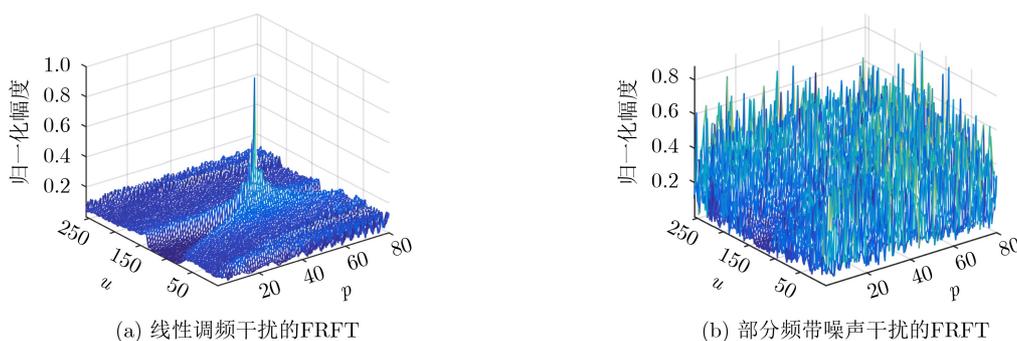


图3 通信干扰信号的FRFT图

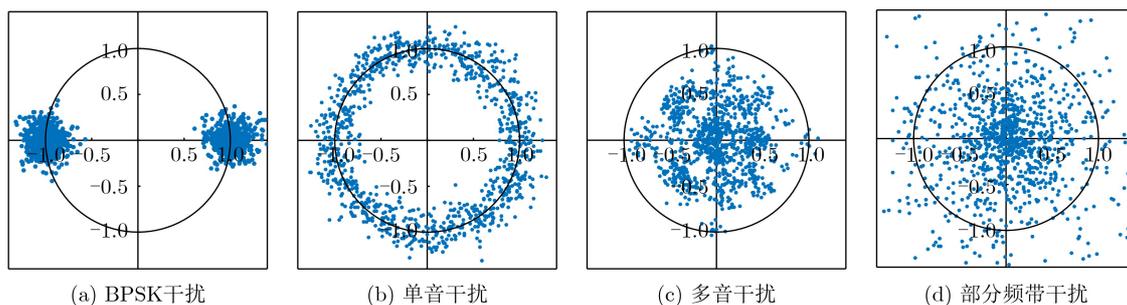


图4 通信干扰信号的星座图

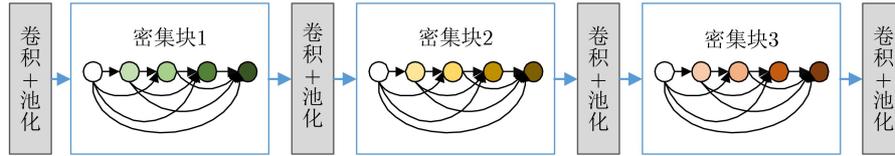


图5 基于DenseNet的子网络结构

核数量为8, 随后再通过3个过渡层和2个密集块之后到达全连接层, 最后使用归一化指数函数(softmax)获取分类结果。

密集块中使用卷积层提取特征的过程可以表示为

$$x_j^l = \text{ReLU} \left(\sum_{i \in M_j} x_i^{l-1} \times K_{ij}^l + b_j^l \right) \quad (15)$$

其中, $\text{ReLU}(x) = \max(0, x)$ 为激活函数, x_j^l 表示第 l 层输出中的第 j 个智能表征, K_{ij}^l 为卷积核, b_j^l 为偏置项。在智能表征进入卷积层之前需要对其进行批归一化, 以保持训练与测试数据保持同样的分布, 防止梯度扩散, 批归一化可表示为

$$y_i = \gamma \frac{x_i - \mu_x}{\sqrt{\sigma^2 + \varepsilon}} + \beta \quad (16)$$

其中, ε 为一个接近0的正数, 避免分母为0, γ 和 β 为可学习参数, μ_x 为样本的均值, σ^2 为样本的方差, μ_x 和 σ^2 可分别表示为

$$\mu_x = \frac{1}{m} \sum_{i=1}^m x_i \quad (17)$$

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_x)^2 \quad (18)$$

其中, m 为训练分批(mini-batch)的大小。

池化层为对智能表征的降采样, 统计某一邻域的特征作为该区域的输出, 从而压缩智能表征大小, 扩大感受野减少过拟合, 本文选择最大池化的方式为

$$y_{m,n} = \max_{0 \leq i < H, 0 \leq j < W} x_{mH+i, nW+j} \quad (19)$$

其中, H 和 W 分别为窗口的高度和宽度。Softmax函数用于最后的分类输出, 它将一个长度为 n 的向量的每一个元素映射到 $(0, 1)$ 之间, 并且全部输出元素的和为1, 它可以表示为

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (20)$$

4.2 基于孪生网络的通信干扰识别

本文提出了一种基于孪生网络的通信干扰识别方法, 孪生网络通过度量两个样本之间的特征距离

来判断样本的相似性^[14], 从而根据最大相似性判断所属的干扰类型。

用于通信干扰识别的孪生网络由两个结构相同的单边网络Network_1和Network_2耦合而成, 且共享参数 W_s , 在优化网络参数时, 训练数据成对出现 (X_1, X_2) , 网络参数的更新采用反向传播算法, 通过最小化损失函数优化模型参数。孪生网络通过卷积层将智能表征映射到新的特征空间, 得到特征向量 $G_W(X_1)$ 和 $G_W(X_2)$, 然后通过特征向量之间的距离 $\text{Dis} < G_W(X_1), G_W(X_2) >$ 来判断特征向量之间的差异, 从而根据特征距离差异来拟合两个智能表征的相似度。随后可将待识别样本与所有已知样本逐一进行相似性对比, 选取相似性最大的样本标签作为识别结果。这种通过比对方式避网络中分类层的大量参数, 减少了过拟合, 同时也解决了样本不均衡问题。不过, 这种逐一比对的方法只能在小样本下实现。

孪生网络的输入形式为 $(X_1 = \gamma_{J_1}, X_2 = \gamma_{J_2})$, 单边网络结构使用基于DenseNet子网络结构, 网络的损失函数为

$$L_{\text{Si}}(x_1, x_2) = \frac{1}{2N} \sum_{m=1}^N Y D_W^2 + (1-Y) \max(m - D_w, 0)^2$$

$$D_W(x_1, x_2) = \|x_1 - x_2\|_2 = \left(\sum_{i=1}^P (x_1^i - x_2^i)^2 \right)^{\frac{1}{2}} \quad (21)$$

其中, $x_1 = G_W(X_1)$ 为单边网络Network_1的输出, $x_2 = G_W(X_2)$ 为单边网络Network_2的输出, $D_W(x_1, x_2)$ 代表特征 x_1 和 x_2 之间的距离, $\|\cdot\|_2$ 为2范数运算, P 为特征维数, Y 为样本标签, 1代表两个样本属于同一干扰类型, 0代表两个样本不属于同一类型, N 为样本对个数, m 为阈值。当 Y 为1时和为0时, 损失函数分别为

$$L(x_1, x_2) = \frac{1}{2N} \sum_{m=1}^N Y D_W^2 \quad (22)$$

$$L(x_1, x_2) = \frac{1}{2N} \sum_{m=1}^N \max(m - D_w, 0)^2 \quad (23)$$

从以上两式明显可以看出, 在两个干扰为同类型时损失函数与干扰特征之间的距离成正比, 为不同类型时损失函数与特征之间的距离成反比, 损失函数

这样的特性使得网络最终缩小了类内特征距离，扩大了类间特征距离。孪生网络的最终的输出是两个干扰样本之间的特征距离，本文对孪生网络进行改进，以得到两个干扰样本为同一类型的概率，如图6所示。首先将孪生网络的损失函数更改为特征距离函数

$$\text{Dis} < G_W(X_1), G_W(X_2) > = \frac{1}{2} D_W^2 \quad (24)$$

然后，孪生网络尾部进行两次密集连接，第1个全连接层的输入为样本对特征距离，输出为

$$y^{i,f_1} = \sigma(W^{f_1} \times \text{Dis} < G_W(X_1), G_W(X_2) > + b^{f_1}) \quad (25)$$

其中， W^{f_1} 和 b^{f_1} 分别为添加的第1层全连接的权重和偏置， i 表示第 i 个样本对， σ 为ReLU激活函数。第2层全连接层只有一个神经元，激活函数选择sigmoid函数，其输出为

$$y^{i,f_2} = \sigma(W^{f_2} \times y^{i,f_1} + b^{f_2}) \quad (26)$$

其中， W^{f_2} 和 b^{f_2} 分别为添加的第2层全连接的权重和偏置， σ 为sigmoid激活函数， $\text{sigmoid}(x) = 1/(1+e^{-x})$ ，该激活函数值域为(0, 1)，最终将样本对特征距离映射为概率值。

该网络的损失函数为交叉熵损失函数，干扰样本对为同类型时，标签 y 设为1，为不同类型时，标签设为0

$$L_s = -y \log_2(y^{i,f_2}) - (1 - y) \log_2(1 - y^{i,f_2}) \quad (27)$$

该网络同样使用梯度反向传播的方式进行权重更新，训练过程与测试分开进行。在训练的过程中从所有类型干扰信号中随机抽取样本对，并设置标签。测试过程使用训练好的单边网络对所有干扰信号样本进行特征提取，获得样本特征数据库 $G(\lambda_{k,i})$ ， $(1 \leq k \leq K, 1 \leq i \leq N_K)$ ， $\lambda_{k,i}$ 代表第 k 类干扰信号第 i 个样本， K 为干扰类型数量， N_K 为每种

干扰类型的样本数量。然后使用单边网络对待测试信号进行特征提取，并与特征样本库 $G(\lambda_{k,i})$ 中所有干扰信号特征进行一一对比，检索特征样本库中相似概率最大的样本标签作为待识别信号标签，从而完成识别。

综上所述，本文所提出的空地协同场景下基于孪生网络的通信干扰智能识别方法的具体步骤如下：

步骤1 提取多类型通信干扰信号的SPWVD时频图、FRFT图和星座图进行智能表征，并构建训练集；

步骤2 构建双输入权值共享的孪生卷积神经网络；

步骤3 随机从训练集中各抽取两个信号样本组成随机信号样本对，使用该随机样本对对孪生网络进行训练；

步骤4 提取孪生网络中的一个单边网络，将训练集中的全部信号样本输入到单边网络中，完成基准通信干扰类型的特征库；

步骤5 将待识别信号输入单边网络得到其特征并与数据库中的数据进行相似性比较，遍历检索出相似概率最高的干扰类型，从而完成了通信干扰类型的识别。

5 仿真结果及分析

仿真实验使用Python进行网络构建与训练，训练环境为Python3.6，操作系统为Linux，计算框架为Pytorch，并使用GPU(GeForce GTX 2080TI)进行训练加速。选取7种类型的通信干扰，包括单音干扰、多音干扰、部分频带噪声干扰、噪声调频干扰、扫频干扰、随机二进制调制窄带干扰和随机二进制调制宽带干扰；在采样完美同步的假设下，采样频率为10 MHz，每种类型通信干扰的载波频率和初始相位随机设置。多音干扰的音调数目为4，部分频带噪声干扰信号的带宽因子在[0.1, 0.7]随机

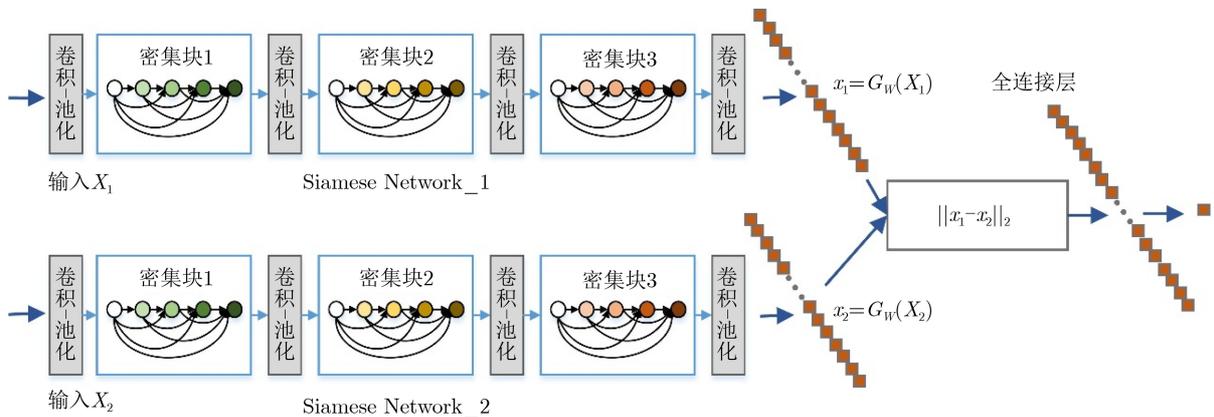


图6 基于孪生网络的通信干扰识别网络

设置，噪声调频干扰的调频系数为0.125~0.933 Hz/s 随机，BPSK干扰的成型函数滚降系数为0.35。训练数据干噪比为-10~15 dB，每种干扰在每个干噪比下生成100个样本，本文干噪比的定义为 $G_{JNR} = 10 \lg(P_J/P_N)$ ，其中， P_J, P_N 分别为干扰信号功率和噪声功率。测试数据为干噪比为-10 dB~15 dB，每种干扰在每个干噪比下生成100个样本。

为了验证所提基于孪生网络的通信干扰识别方法的有效性，干扰类型数量和参数和保持不变，训练集和测试集设置同样保持一致，学习率设置为0.005，batch size设置为105，其仿真结果如图7所示。从图7可以看出，各类干扰信号识别率随干噪比提高而增长，当干噪比为2 dB时识别正确率达到90%以上，当干噪比为6 dB时识别正确率为100%，可见所提方法能够有效地对通信干扰进行识别。

考虑到多普勒频移变化对本文方法识别性能的影响，将频率偏移分别设置为10 kHz, 20 kHz, 40 kHz，测试其在不同干噪比下的识别性能，仿真结果如图8所示。从图8可以看出，不同频率偏移下干扰识别准确率曲线随信噪比的增加而上升，当干噪比1 dB时识别正确率均上升至90%，当干噪比6 dB时识别正确率均接近100%。因此，所提干扰识别方法对频偏是稳健的。

考虑到Rayleigh衰落信道对本文方法识别性能

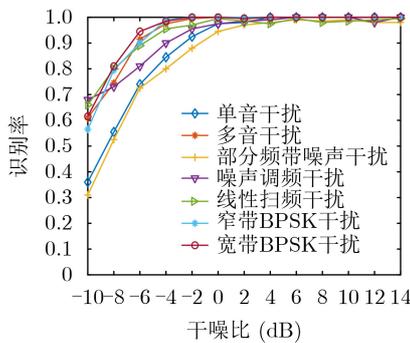


图7 基于孪生网络的通信干扰识别性能

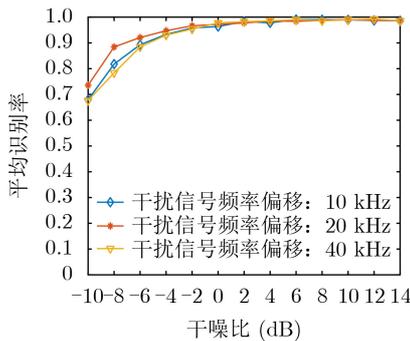


图8 不同频率偏移下通信干扰的识别性能

的影响，将干扰信号信道设置为平坦Rayleigh衰落信道，Rayleigh衰落信道多普勒频率分别设置为10 Hz, 20 Hz, 30 Hz，测试其在不同干噪比下的识别性能，其仿真结果如图9所示。从图9可以看出，在Rayleigh衰落信道下，当干噪比6 dB时识别正确率90%以上，可见该识别方法在Rayleigh衰落信道下仍是有效的。

为了验证训练样本数量对识别方法性能的影响，干噪比为10 dB，分别设置每类干扰信号训练样本数量为25, 50, 100, 200, 400，将本文提出的识别方法与基于模型无关元学习(Model-Agnostic Meta-Learning, MAML)的识别方法^[15]和文献[6]方法进行对比，其仿真如图10所示，3种识别方法的正确识别率随训练样本数量增加而提升。当样本数量为25时，本文所提方法性能最好，文献[6]方法性能最差，当训练样本数量为50, 100, 200时，本文所提方法的识别性能明显优于文献[6]方法，在样本量为400时，3种方法性能较为接近。可见，本文所提方法在小样本情况下识别性能更优。

为了对比不同通信干扰识别方法的性能，在一致的实验环境下，将本文提出的识别方法与文献[6]、文献[8]方法进行对比，干扰类型为单音干扰、多音干扰、LFM干扰、部分频带干扰和噪声调频干扰，每种干噪比下每种信号的训练样本数量为100，其对比结果如表1所示。从表1可以看出，本文所提方

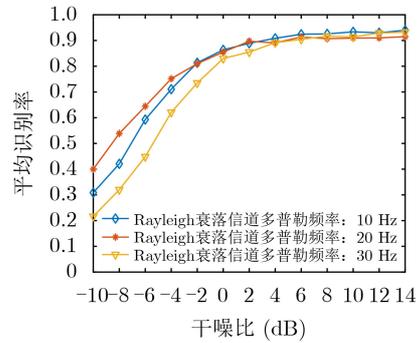


图9 不同Rayleigh衰落信道下子网络识别性能图

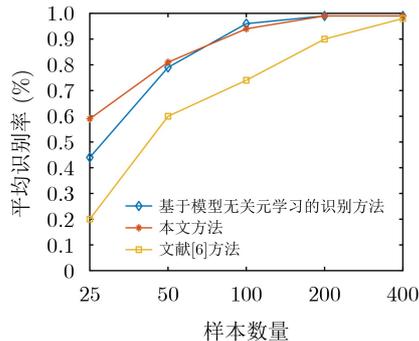


图10 不同样本数量下不同识别方法的性能对比

表1 不同通信干扰识别方法的性能对比(%)

不同的识别方法	信噪比(dB)				
	-4	0	4	8	12
本文方法	96.00	97.71	98.43	98.14	99.14
文献[6]方法	83.54	86.74	95.46	95.84	96.30
文献[8]方法	84.00	97.10	98.43	98.14	99.14

法在干噪比为-4 dB时平均识别率均达到了96%，明显优于文献[6]方法和文献[8]方法。可见，本文所提方法在低干噪比下识别性能更佳。在相同GPU硬件加速条件下，本文方法的离线训练时间为913.87 s，文献[6]方法的离线训练时间为1009.51 s，文献[8]方法的离线训练时间为3656.42 s。可见，本文方法的时间复杂度均低于文献[6]方法和文献[8]方法。

6 结束语

本文研究了空地协同场景下小样本学习的通信干扰识别问题，提出了一种基于孪生网络的通信干扰智能识别方法。该方法首先分析了通信干扰信号的SPWVD时频图、分数阶傅里叶变换和星座图，并将其作为智能表征输入到网络，然后借鉴DenseNet的网络思想构建了基于DenseNet的网络结构，在此基础上，设计双输入权值共享的孪生网络对多类型的通信干扰进行了智能识别。仿真结果表明，本文所提的识别方法可以有效提升小样本条件下通信干扰的识别性能，且适用于空地协同的认知环境。

参考文献

- [1] JOHNSTON J, LI Yinchuan, LOPS M, *et al.* ADMM-net for communication interference removal in stepped-frequency radar[J]. *IEEE Transactions on Signal Processing*, 2021, 69: 2818–2832. doi: [10.1109/TSP.2021.3076900](https://doi.org/10.1109/TSP.2021.3076900).
- [2] KE Chenxi, LI Jingwen, CHENG Wei, *et al.* An intelligent anti-interference communication method based on game learning[C]. The 2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference, Chongqing, China, 2021: 182–186. doi: [10.1109/IAEAC50856.2021.9390621](https://doi.org/10.1109/IAEAC50856.2021.9390621).
- [3] 黄国策, 王桂胜, 任清华, 等. 基于Hilbert信号空间的未知干扰自适应识别方法[J]. 电子与信息学报, 2019, 41(8): 1916–1923. doi: [10.11999/JEIT180891](https://doi.org/10.11999/JEIT180891).
HUANG Guoce, WANG Guisheng, REN Qinghua, *et al.* Adaptive recognition method for unknown interference based on Hilbert signal space[J]. *Journal of Electronics & Information Technology*, 2019, 41(8): 1916–1923. doi: [10.11999/JEIT180891](https://doi.org/10.11999/JEIT180891).
- [4] 冯嫚, 王梓楠. 基于奇异值分解与神经网络的干扰识别[J]. 电子与信息学报, 2020, 42(11): 2573–2578. doi: [10.11999/JEIT190228](https://doi.org/10.11999/JEIT190228).
FENG Man and WANG Zinan. Interference recognition based on singular value decomposition and neural network[J]. *Journal of Electronics & Information Technology*, 2020, 42(11): 2573–2578. doi: [10.11999/JEIT190228](https://doi.org/10.11999/JEIT190228).
- [5] HUANG Liang, ZHANG You, PAN Weijian, *et al.* Visualizing deep learning-based radio modulation classifier[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2021, 7(1): 47–58. doi: [10.1109/TCCN.2020.3048113](https://doi.org/10.1109/TCCN.2020.3048113).
- [6] 党泽. 基于深度学习的无线通信干扰信号识别与处理技术研究[D]. [硕士学位论文], 电子科技大学, 2020. doi: [10.27005/d.cnki.gdzku.2020.004101](https://doi.org/10.27005/d.cnki.gdzku.2020.004101).
DANG Ze. Research on the technology of wireless communication interference signal identification and processing based on deep learning[D]. [Master dissertation], University of Electronic Science and Technology of China, 2020. doi: [10.27005/d.cnki.gdzku.2020.004101](https://doi.org/10.27005/d.cnki.gdzku.2020.004101).
- [7] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, *et al.* Generative adversarial nets[C]. The 27th International Conference on Neural Information Processing Systems, Montreal, Canada, 2014: 2672–2680. doi: [10.5555/2969033.2969125](https://doi.org/10.5555/2969033.2969125).
- [8] 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.
- [9] 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, San Diego, USA, 2005: 539–546. doi: [10.1109/CVPR.2005.202](https://doi.org/10.1109/CVPR.2005.202).
- [10] NOROUZI M, FLEET D J, and SALAKHUTDINOV R. Hamming distance metric learning[C]. The 25th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012: 1061–1069. doi: [10.5555/2999134.2999253](https://doi.org/10.5555/2999134.2999253).
- [11] VINYALS O, BLUNDELL C, LILLICRAP T, *et al.* Matching networks for one shot learning[C]. *Proceedings of*

- the 30th International Conference on Neural Information Processing Systems*, Barcelona, Spain, 2016: 3637–3645. doi: [10.5555/3157382.3157504](https://doi.org/10.5555/3157382.3157504).
- [12] XU Lu, YIN Xingyao, ZONG Zhaoyun, *et al.* Synchrosqueezing matching pursuit time–frequency analysis[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(3): 411–415. doi: [10.1109/LGRS.2020.2978877](https://doi.org/10.1109/LGRS.2020.2978877).
- [13] SHI Jun, ZHENG Jiabin, LIU Xiaoping, *et al.* Novel short-time fractional Fourier transform: Theory, implementation, and applications[J]. *IEEE Transactions on Signal Processing*, 2020, 68: 3280–3295. doi: [10.1109/TSP.2020.2992865](https://doi.org/10.1109/TSP.2020.2992865).
- [14] CHICCO D. Siamese Neural Networks: An Overview[M]. New York: Humana, 2021: 73–94. doi: [10.1007/978-1-0716-0826-5_3](https://doi.org/10.1007/978-1-0716-0826-5_3).
- [15] YANG Ning, ZHANG Bangning, DING Guoru, *et al.* Specific emitter identification with limited samples: A model-agnostic meta-learning approach[J]. *IEEE Communications Letters*, 2022, 26(2): 345–349. doi: [10.1109/LCOMM.2021.3110775](https://doi.org/10.1109/LCOMM.2021.3110775).
- 刘明骞: 男, 1982年生, 博士, 副教授, 博士生导师, 研究方向为电磁信号智能处理和电磁信号大数据处理.
- 高晓腾: 男, 1994年生, 硕士, 助理工程师, 研究方向为信号处理.
- 李 明: 男, 1984年生, 博士, 正高级工程师, 研究方向为电子侦察和智能化电子对抗.
- 朱守中: 男, 1982年生, 博士, 高级工程师, 研究方向为航天电子侦察和要地低空防护.

责任编辑: 马秀强