

低空物联网中基于多质心 OpenMax 的无人机开集识别方法

杨宁, 胡景明, 张邦宁, 丁国如, 郭道省

(陆军工程大学通信工程学院, 南京 210007)

摘要: 随着网络化、智能化的发展, 无人机(Unmanned aerial vehicles, UAVs)逐渐成为低空物联网(Low-altitude intelligent network, LAIN)的重要组成部分, 但如何对低空物联网中的无人机平台进行有效的管理仍面临严峻挑战。基于无人机信号中的细微特征可对无人机进行个体识别, 并检测是否为非法无人机, 从而实现低空物联网中无人机的身份识别和管理。针对低空领域信道环境复杂且无法提前获取非法无人机信号样本的问题, 本文提出了基于差值时频和多质心 OpenMax 的无人机开集识别方法。首先, 提出了与信道无关的差值时频特征来降低多径信道环境对射频指纹(Radio frequency fingerprinting, RFF)特征的影响, 并利用数据增强提高了识别模型的准确率和鲁棒性。其次, 利用多质心 OpenMax 替代神经网络 Softmax 层, 以实现无人机个体的开集识别。最后, 对神经网络的损失函数进行了改进, 提高了开集识别准确率。本文利用真实环境采集的数据对所提算法进行了验证, 在多径信道环境中开放度为 0.087 时, 开集识别准确率达到 93.23%, 与基准算法相比, 准确率分别提高了 7.61% 和 13.4%。本文提出的算法可在复杂信道环境中有效识别无人机个体并检测出首次出现的非法无人机。

关键词: 低空物联网; 开集识别; 射频指纹; 多径信道环境; 非法无人机

中图分类号: TN911.7 **文献标志码:** A

Open Set Identification Method for Unmanned Aerial Vehicles Based on Multi-center OpenMax in Low-Altitude Intelligent Network

YANG Ning, HU Jingming, ZHANG Bangning, DING Guoru, GUO Daoxing

(College of Communication Engineering, Army Engineering University of PLA, Nanjing 210007, China)

Abstract: With the development of networked and intelligent unmanned aerial vehicles (UAVs), they have gradually become an important component of the low-altitude intelligent network (LAIN). However, the effective management of UAV platforms in the LAIN still faces severe challenges. Based on the subtle features of UAV signals, individual identification of UAVs can be achieved, and illegal UAVs can be detected, thereby realizing the identification and management of UAVs in the LAIN. In response to the problem of complex channel environments and the inability to obtain illegal UAV signal samples in advance in the low-altitude domain, this paper proposes an open set identification method for UAVs based on differential time-frequency and multi-center OpenMax. Firstly, this paper proposes channel-independent differential time-frequency features to reduce the impact of multipath channel environments on radio frequency fingerprinting (RFF) features and uses data augmentation to improve the accuracy and

robustness of the identification model. Secondly, this paper uses multi-center OpenMax to replace the neural network's SoftMax layer for open set identification of UAVs. Finally, the loss function of the neural network is improved to increase the accuracy of open set recognition. The proposed algorithm is validated using real-world data. When the openness is 0.087, the open set recognition accuracy reaches 93.23%, an increase of 7.61% and 13.4% compared with the benchmark algorithms. The algorithm proposed in this paper can effectively identify individual UAVs and detect illegal UAVs appearing for the first time in complex channel environments.

Key words: low-altitude aerial intelligent network; open set identification; radio frequency fingerprinting; complex channel environment; illegal UAVs

引 言

低空智能网(Low-altitude intelligent network, LAIN)是指在低空空域融合运用网络化、数字化和智能化技术构建的智能化数字网络体系,对于发展我国低空经济具有重要意义。无人机(Unmanned aerial vehicle, UAV)作为可执行各种任务的空中移动智能体,是低空智能网的重要组成部分,但如何对其进行有效监管仍是低空智能网发展过程中亟待解决的问题。

由于在低空智能网中无人机“低、慢、小”的特点,现有的雷达探测、红外探测和声波探测等方式极易受城市背景噪声的影响,很难精准探测到无人机,且这些方式只能发现无人机但无法对其进行识别。虽然利用加密算法也可实现安全验证,但加密算法被破解的可能性越来越大,且无人机算力受限,因此传统基于加密算法的安全验证并不适合低空智能网。而利用射频指纹(Radio frequency fingerprinting, RFF)^[1]为低空智能网的安全管控提供了另一种可行的低成本方案。所有的电子器件都会有不同程度的缺陷,这些缺陷会对信号形成无意识调制,被称为射频指纹。即使相同型号、同一批次的电子器件的射频指纹也互不相同,因此每个无人机的通信信号的射频指纹都相当于它们唯一的“ID”。利用无人机的通信信号进行个体识别,进而确定无人机身份,便可以实现无人机的识别与认证^[2]。低空智能网中基于无人机通信信号的个体识别的主要流程如图1所示,利用接收的无人机信号中包含的射频指纹信息进行个体识别,首先判断信号是否来自数据库内已知的无人机;若不是则判断为非法无人机,若来自数据库内,则进行进一步的个体识别。

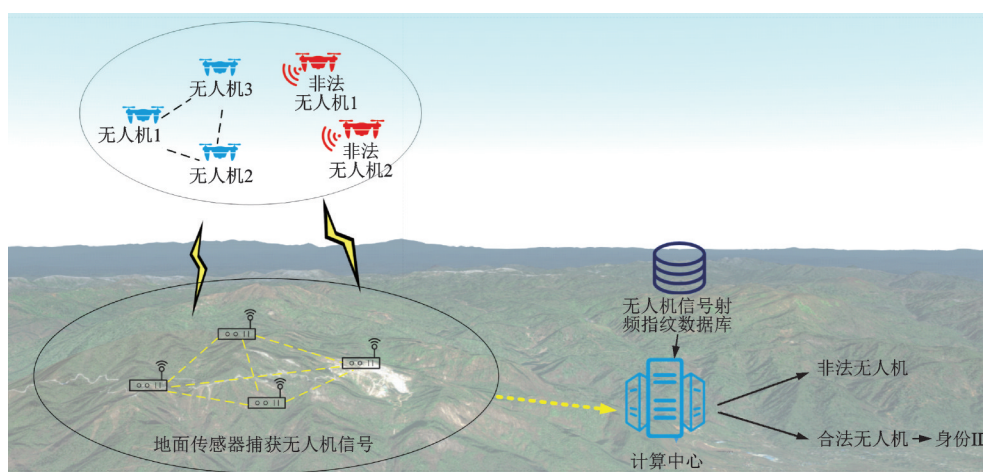


图1 低空智能网中无人机个体识别主要流程

Fig.1 Main process of individual identification of UAVs in LAIN

基于射频指纹的个体识别算法又被称为辐射源个体识别(Specific emitter identification, SEI)。由于个体识别是基于无人机发射的信号进行,因此可将无人机视为辐射源的一种。传统辐射源个体识别方法通常利用信号的瞬时部分和稳态部分提取出不同的指纹特征,并据此实现识别^[3]。然而,这些方法需要极强的专业知识。随着深度学习的发展,更多有效的方法,如卷积神经网络^[4]和深度残差网络^[5]等被提出来。与传统方法相比,深度学习算法可以提取更加复杂的内部表示,从而实现更细粒度的识别。

然而大多数有监督辐射源个体识别算法都是基于测试数据中包含的辐射源个体必须出现在训练集中的假设,这通常被称为封闭世界假设。也就是说一旦模型训练完成,只能识别训练集中已知的辐射源,当有新的非法无人机出现时,模型会将其以较低的可能性识别为某一个已知无人机,这明显是不合理的。但是训练集几乎不可能涵盖所有无人机个体的信号,且很难提前获取非法无人机的信号样本,因此开集学习更适合此类情况。它不仅可以识别训练集中的无人机,同时可以检测新的无人机。

开集学习定义为:一个利用训练数据集训练好的神经网络,当利用测试数据集(包括不存在训练数据集中的未知类别)进行测试时,如果输入已知类别样本,则可以输出具体识别结果,如果输入未知类别样本,则识别为“未知”。因此利用开集学习在实现无人机个体识别的同时,可识别前期未采集到样本的非法无人机,具体如图2所示。近年来,基于开集学习的个体识别算法陆续被提出。文献[6]将未知辐射源的识别描述为开集识别和异常检测,在未获得未知辐射源样本且有预训练好的分类器的情况下,OpenMax的识别性能最好;文献[7-8]将无标签的未知辐射源样本加入训练集,以得到可检测未知辐射源分类器,但由于未知辐射源的出现具有不可预测性,难以提前获取信号样本,故此方法并不适合实际场景;文献[9-10]利用原型学习增大不同辐射源特征的类间距离,从而根据距离阈值检测未知辐射源;文献[11]通过堆栈去噪自编码器实现降噪和特征压缩提取,并基于支持向量描述实现了通信辐射源个体开集识别;文献[12]提出了基于孪生网络的通信辐射源开集识别算法,但是作者使用的数据集是不同型号的手机蓝牙数据。射频指纹在不同型号的辐射源之间区别明显大于相同型号。上述开集识别模型大都仅考虑了高斯白噪声的影响,未考虑实际场景中多径信道对未知辐射源检测的影响。由于无线信道的开放性,接收信号极易受到信道环境的影响,当辐射源所处信道环境发生变化时,射频指纹的特征空间发生扭曲变形,不仅导致闭集识别急剧下降,开集识别模型也极易将训练集中出现的辐射源误识别为新增未知辐射源。

文献[13]最先提出利用OpenMax实现开集识别,但主要针对单峰分布的数据。本文对射频指纹特征向量的分布进行可视化,其局部密度分布如图3所示,射频指纹特征向量呈现出多峰、非均匀的特点。在此背景下,本文提出一种基于多质心OpenMax的无人机开集识别方法,通过改变神经网络的激活函

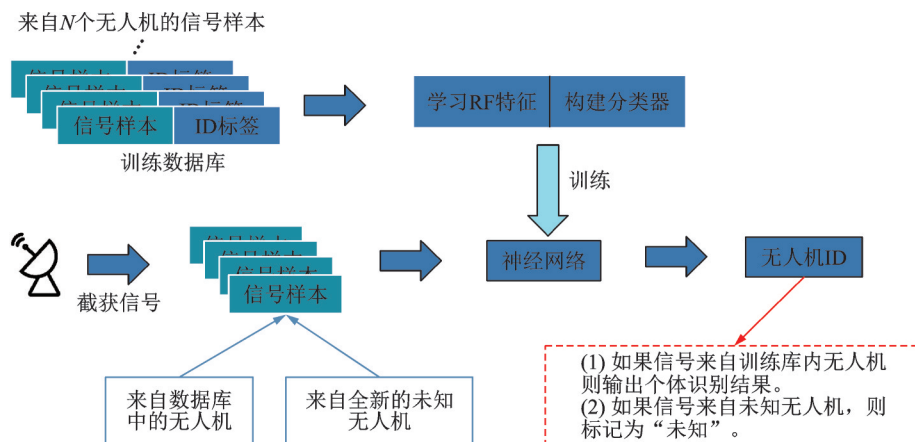


图2 基于开集学习的无人机个体识别功能示意图

Fig.2 UAV individual identification based on open set learning

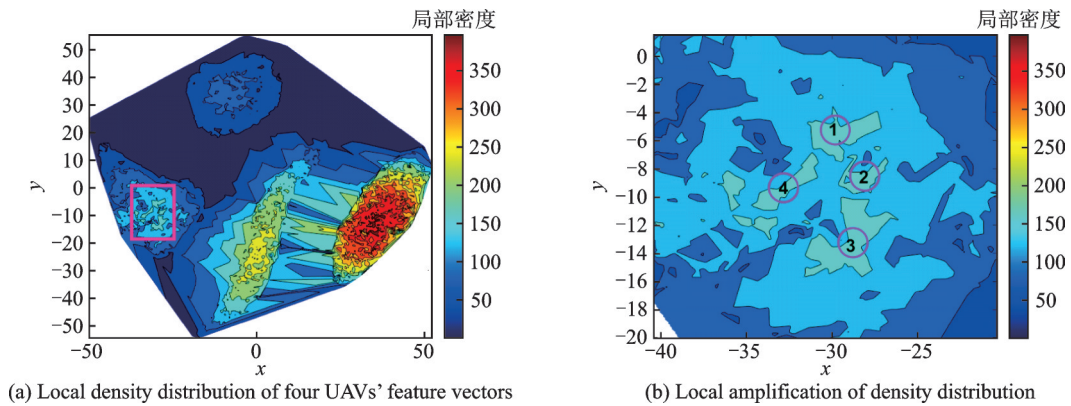


图3 特征向量局部密度分布图

Fig.3 Local density distribution of feature vectors

数,实现了无人机的开集识别,在保持已知无人机个体识别性能的同时,可识别首次出现的未知无人机。同时对神经网络的损失函数进行了进一步的改进以增大射频指纹特征的类间距离,提高了模型准确率。本文的主要贡献如下:

- (1) 针对识别算法性能易受信道环境变化影响的问题,提出了差值时频特征来降低信道的影响,并利用数据增强提高识别模型的鲁棒性。
- (2) 利用多质心 OpenMax 对神经网络结构进行设计,实现了对新增未知辐射源的识别即非法无人机的检测。
- (3) 对神经网络的损失函数进行设计,增大了 RFF 特征空间的类间距离,提高了未知无人机的检测准确率。
- (4) 利用实测数据对所提算法进行性能测试,并与其他算法对比验证了所提方法的优越性。

1 系统模型和问题描述

如图4所示,以超外差发射机为例,数字信号首先经过数模转换器变为模拟信号,而后经过两次上变频变为射频信号,最后通过功率放大器和频带滤波器,并通过天线发射出去。在射频信号产生的过程中,硬件容差会令信号产生细微差异,例如本地振荡器的频偏和相位噪声、功率放大器的非线性失真等,这些细微差异便是射频指纹产生的原因。如图5所示,通过信号接收、预处理、特征提取、识别与分类4个阶段实现无人机个体识别。预处理阶段的主要任务是在接收信号中选取一段感兴趣的区域,并对该区域的信号进行归一化、去噪等预处理,得到待识别信号,用于后续的射频指纹提取。特征提取阶段的主要任务是对波形进行频域分析,时频分析、分形、高阶谱等各种变换域方法获取RFF,也可以在调制域提取RFF特征,当特征维数过高时还需要进行降维处理。识别与分类阶段的主要任务是根据所提取特征的维度和需要实现的分类功能,选择合适的分类器实现无人机个体识别,现在主要采用深度学习中的神经网络。




图4 发射机模型

Fig.4 Transmitter model

1.1 接收信号模型

发射机发射的信号可表示为

$$x(t) = a(t)e^{j[2\pi f_c t + \varphi(t)]} \quad (1)$$

式中: $a(t)$ 和 $\varphi(t)$ 分别表示信号的振幅和相位; f_c 为载波频率。考虑硬件

非线性导致的无意识调制,接收到的信号可表示为

$$s(t) = F[x(t)] = [a(t) + \Delta a(t)]e^{j[2\pi(f_c + \Delta f(t))t + (\varphi(t) + \Delta\varphi(t))]} \quad (2)$$

式中: $F[*]$ 表示发射机的无意识调制; $\Delta a(t)$ 、 $\Delta f(t)$ 和 $\Delta\varphi(t)$ 分别表示无意识调制导致的幅度、频率和相位的细微变化。由于多径效应和信道时变性,接收的信号中不仅包含了无意识调制信息,同样包含了当前信号所经历的信道特点。接收的信号可表示为

$$r(t) = H\{F[x(t)]\} = \sum_n b_n(t)s(t - \tau_n(t)) + n(t) = h(t)*s(t) + n(t) \quad (3)$$

式中: $H[*]$ 表示信道的影响; $b_n(t)$ 和 $\tau_n(t)$ 分别为第 n 条路径上接收信号的衰减因子和传播时延; $h(t)$ 表示当前信道的冲击响应,可表示为

$$h(t) = \sum_{k=1}^n b_k \delta(t - \tau_k T_s) \quad (4)$$

式中: b_k 表示第 k 条路径上接收信号的衰减因子; δ 表示冲击响应函数; τ_k 表示第 k 条路径的时延因子; T_s 表示采样周期。

1.2 开集识别问题描述

开集识别中的样本可划分为4类:已知辅助信息的已知类(Known known classes, KKC)s、无辅助信息的已知类(Unknown known classes, UKCs)、已知辅助信息的未知类(Known unknown classes, KUCs)和未知辅助信息的未知类(Unknown unknown classes, UUCs)。本文所研究的待识别的数据分为两类:参与识别网络训练过程的带标签数据、从未在训练数据集中出现的无标签的未知无人机数据,因此仅涉及KKCs和UUCs。训练数据集中的样本均带标签,可表示为 $D_{tr} = \{(x_i \in X_{tr}, y_i \in Y_{tr} = \{1, 2, \dots, N_{TR}\})\}$,测试数据集中可能包含没有标签的从未在训练数据集中出现的未知无人机信号样本,其形式为 $D_{te} = \{(x_i \in X_{te}, y_i \in Y_{te} = \{1, 2, \dots, N_{TR}, \dots, N_{TE}\})\}$ 。其中 X_{tr} 表示训练数据集样本集合, Y_{tr} 表示训练数据集标签集合, X_{te} 表示测试数据集样本集合, Y_{te} 表示测试数据集标签集合, N_{TR} 表示训练集中的类别数, N_{TE} 表示测试集中的类别数。如图6和图7所示,与封闭环境中的识别不同的是,开集识别不仅能正确识别KKCs中的无人机个体,同时可以拒绝UUCs。

文献[14]给出开放度的定义为

$$O = 1 - \sqrt{\frac{2 \times |N_{TR}|}{|N_{TR}| + |N_{TE}|}} \quad (5)$$

当 $O = 0$ 时表示闭集识别。 R_{KKC}^m 和 R_{UUC}^m 分别为已知样本空间和未知样本空间,那么 $R^m = R_{KKC}^m \cup R_{UUC}^m$ 且 $R_{KKC}^m \cap R_{UUC}^m = \emptyset$ 。开放空间风险定义为



图5 无人机个体识别工作流程

Fig.5 Workflow of UAV individual identification




图6 闭集识别

Fig.6 Closed set identification




图7 开集识别

Fig.7 Open set identification

$$R_o(f) = \frac{\int_{R_{\text{uc}}}^m f(x) dx}{\int_{R^m} f(x) dx} \quad (6)$$

式中 $f(x)$ 为分类函数。对于给定训练数据集 D_{tr} , 开放集风险可表示为^[13]

$$R_o(f) + \lambda R_\epsilon(f(D_{\text{tr}})) \quad (7)$$

式中: λ 为正则化常数; R_ϵ 表示经验风险。此时, 开集识别的目标为

$$\arg \min_{f \in F} \{R_o(f) + \lambda R_\epsilon(f(D_{\text{tr}}))\} \quad (8)$$

无人机开集识别就是找到一个合适的模型 f 来最小化开放集风险同时平衡经验风险。

2 差值时频特征

如前所述, 接收信号不仅包含射频指纹特征, 还包含信道特征。为此本文提出了与信道无关的差值时频特征, 以减轻时频域中的信道效应, 同时保持信号中包含的无意识调制特征。

短时傅里叶变换 (Short-time Fourier transform, STFT) 是一种常用的时频分析算法, 可以揭示信号的时频特征, 且在文献 [15] 中被用于辐射源个体识别, 离散 STFT 表达式为

$$R_{k,m} = \sum_{n=0}^{N-1} r(n) w[n - mR] e^{-j2\pi \frac{k}{N} n} \quad k = 1, 2, \dots, N; \quad m = 1, 2, \dots, M \quad (9)$$

式中: $R_{k,m}$ 表示 STFT 后的时频矩阵 R 中的元素; N 和 M 分别为 R 的行数和列数; $w(n)$ 表示窗函数。

STFT 可以认为是将信号 $r(n)$ 分成 M 段变为 N 个样本, 然后对每个样本进行 FFT。因此, STFT 后的时频矩阵可表示为

$$R = \begin{bmatrix} H_{1,1}F(X_{1,1}) & H_{1,2}F(X_{1,2}) & \cdots & H_{1,M}F(X_{1,M}) \\ H_{2,1}F(X_{2,1}) & H_{2,2}F(X_{2,2}) & \cdots & H_{2,M}F(X_{2,M}) \\ \vdots & \vdots & \vdots & \vdots \\ H_{N,1}F(X_{N,1}) & H_{N,2}F(X_{N,2}) & \cdots & H_{N,M}F(X_{N,M}) \end{bmatrix} = [H_1 \odot F_1 \quad H_2 \odot F_2 \quad \cdots \quad H_M \odot F_M] \quad (10)$$

式中: $X_m = [X_{1,m}, X_{2,m}, \dots, X_{N,m}]^T$ 表示第 m 段理想信号的频谱; $H_m = [H_{1,m}, H_{2,m}, \dots, H_{N,m}]^T$ 表示信道对第 m 段信号的影响; \odot 表示矩阵元素积。对时频矩阵 R 各元素取绝对值后求对数, 变为

$$\ln |R| = \ln |H_1| + \ln |F_1| \quad \ln |H_2| + \ln |F_2| \quad \cdots \quad \ln |H_M| + \ln |F_M| \quad (11)$$

假设信道为慢衰落信道, 在短时间内不会发生显著变化, 因此 $|H_m| \approx |H_{m+1}|$ 。本文将第 m 列减第 $(m+1)$ 列, 这样就可以消除与信道相关的信息, 处理后的矩阵如下

$$S = \ln |F_1| - \ln |F_2| \quad \ln |F_2| - \ln |F_3| \quad \cdots \quad \ln |F_{M-1}| - \ln |F_M| \quad (12)$$

将上述差值短时傅里叶变换矩阵 (Difference short time Fourier transform, DSTFT) 作为射频指纹特征输入神经网络, 可以有效减少信道环境改变对识别准确率的影响。

3 多质心 OpenMax

3.1 神经网络激活函数

卷积神经网络倒数第二层的输出 $v(x)$ 称为激活向量。设 $v(x) = v_1(x), v_2(x), \dots, v_N(x)$ 为 N 类的激活向量。Sofmax 层根据 $v(x)$ 计算当前输入 x 属于各个类别的得分

$$P(y = j|x) = \frac{e^{v_j(x)}}{\sum_{i=1}^N e^{v_i(x)}} \quad (13)$$

式中分母对属于每一类的概率求和,结果为1。但在开集识别中,还包含未知类,此时仅对 N 分类概率求和便为1,是不合理的。为此本文引入 OpenMax 替换神经网络的激活函数 Softmax。

3.2 多质心 OpenMax

OpenMax 根据特征向量距离特征中心的距离来修正分类得分,从而区分已知和未知无人机,其核心在于极值理论 (Extreme value theory, EVT)。根据文献[16],极大值的分布服从 Weibull 分布,其累计分布函数形式为

$$F(x; \lambda, k) = \begin{cases} 1 - e^{-\left(\frac{x}{\lambda}\right)^k} & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (14)$$

式中 x 为随机变量; $\lambda > 0$ 为比例参数; $k > 0$ 为形状参数。

由于特征向量并不是均匀分布的,为了更好地拟合特征空间的分布,本文将传统的 OpenMax 算法改为多质心 OpenMax。采用 K-means 算法得到每类样本特征空间的质心集合 $C = \{c_{i,j}\}$, 其中 $i = 1, 2, \dots, N$ 表示 N 分类, $j = 1, 2, \dots, p$ 表示每一类有 p 个质心。对于每一个质心,均可以拟合得到一个 Weibull 分布模型。样本离质心的距离的极大值分布变为

$$F(x; \lambda, k) = \sum_{i=1}^q \alpha_i F_i(x; \lambda, k) \quad (15)$$

式中 α_i 表示权重系数且 $\sum_{i=1}^q \alpha_i = 1$, 特征空间中特征向量越密集,其概率权重越大。总的来说, OpenMax 就是根据未知无人机的样本拟合得到 Weibull 模型判断闭集分类模型分类错误概率,并根据其来矫正已知类得分并计算未知类得分,其步骤如算法 1 所示。

算法 1 基于多质心 OpenMax 的无人机个体识别算法

参数: 激活向量 $\mathbf{v}(x) = v_1(x), v_2(x), \dots, v_N(x)$

参数: 质心集合 C 和对应的 Weibull 分布概率函数 $F_i(x; \lambda, k)$

参数: β , 要修改识别概率的类别数

(1) 令 $s(i) = \arg \text{sort}(v_j(x))$

(2) for $i = 1, \dots, \beta$ do

$$(3) w_{s(i)}(x) = \sum_{m=1}^p \alpha_m \left(1 - \frac{\beta - i}{\beta} e^{-\left(\frac{\|x - c_{i,m}\|}{\lambda_{s(i)}}\right)^k} \right)$$

(4) end for

(5) 重新计算激活向量 $\mathbf{v}'(x) = \mathbf{v}(x) \times (1 - w(x))$

(6) 定义 $v'_{N+1}(x) = \sum_i v_i(x) - v'_i(x)$

$$(7) \hat{P} = (y = j|x) = \frac{e^{\hat{v}_j(x)}}{\sum_{i=1}^{N+1} e^{\hat{v}_i(x)}}$$

(8) 识别结果变为 $y^* = \arg \max \hat{P} = (y = j|x)$

(9) 如果 $y^* = N + 1$ 表示待识别无人机为非法无人机

3.3 损失函数

为了使同类样本之间更加紧凑,不同样本之间更加分散,本文在神经网络的损失函数中加入 center loss, 可表示为

$$L_C = \frac{1}{2} \sum_{i=1}^m \|v_i(\mathbf{x}) - c_{y_i}\|_2^2 \quad (16)$$

式中: m 为一次训练所抓取的数据样本数量; c_{y_i} 表示第 y_i 个类别的特征中心。具体来说即在训练过程中对每个类别在最小训练批次上统计出该类别特征向量的中心,希望所有特征向量离中心的距离都尽量小。

之前神经网络所用的交叉熵函数为

$$L_S = - \sum_{i=1}^m \lg \frac{e^{v_i(\mathbf{x})}}{\sum_{j=1}^N e^{v_j(\mathbf{x})}} \quad (17)$$

式中 N 为类别总数。

神经网络总的损失函数可表示为

$$L = L_S + \lambda L_C = - \sum_{i=1}^m \lg \frac{e^{v_i(\mathbf{x})}}{\sum_{j=1}^N e^{v_j(\mathbf{x})}} + \frac{\lambda}{2} \sum_{i=1}^m \|v_i(\mathbf{x}) - c_{y_i}\|_2^2 \quad (18)$$

4 实验仿真与结果

4.1 数据信号预处理

本文采用实测数据来验证所提算法的有效性。在空旷的操场上,无人机携带 CC2530 通信模块升空,悬停距离地面 5 m 的位置,并发射通信信号,信号载频设置为 2.4 GHz。地面采用 BB60C 接收机采集无人机信号,并自动保存至其连接的笔记本电脑上。每个设备采集 10 s 的信息,每次采集都尽量使无人机悬停在相同位置。为了保留更多的细微特征,采用了过采样方式,采样率设置为 40 Mb/s。本文一共采集了 10 台设备的信号,分别将其标记为“0”“1”...“9”。采集的数据量约为 15 GB。

使用能量检测法确定信号的起点和终点。设置一个滑动窗口 w ,每次滑动步长为 s 。当窗口位于噪声部分时,相邻窗口内信号能量的比值近似为 1。因此根据以下条件可以判断信号的起点和终点。

$$\text{start: } E_i/E_{i-1} \geq a \quad (19)$$

$$\text{end: } E_i/E_{i-1} \leq b \quad (20)$$

式中: E_i 表示第 i 个窗口内信号能量值; $a > 1$ 且 $b < 1$ 。能量检测后,对信号段信号进行归一化和小波降噪处理,便于后续输入神经网络进行射频指纹提取。

为了增强信号在多径信道环境中的鲁棒性,对实测信号进行数据增强,得到了不同信道环境和信噪比的混合数据集。本文模拟了 2 径和 3 径两种多径信道场景,相关参数如表 1 所示,并对信号随机加上信噪比为 0~20 dB 的高斯白噪声,得到混合数据集。

表 1 多径信道参数

Table 1 Parameters of multipath channels

路径	1	2	3
传播时延/ μs	0	0.1	0.2
平均信道增益/dB	0	-4	-8

4.2 输入特征

为了验证提出的差值时频特征抗噪声能力,本文首先利用 5 台无人机的数据训练了一个 5 分类的识别网络。分别将 DSTFT 和 STFT 输入神经网络,结果如图 8 所示。可以看到,如果没有数据增强,仅输入 STFT 作为射频指纹特征时,利用 20 dB 和 0 dB 的数据集训练得到的神经网络识别准确率仅有 28.4% 和 19.6%,几乎没有任何的识别能力;但使用 DSTFT 有 57.2% 和 46.8% 的准确率。为了进一步提高识别准确率,本文进行了数据增强,使用混合数据训练得到的神经网络,在输入为 DSTFT 和 ST-

FT时识别准确率分别达到了95.6%和91.2%。因此即使信道环境发生了变化,利用DSTFT特征和数据增强仍能实现有效识别。

4.3 神经网络结构选择

卷积神经网络(Convolutional neural network, CNN)和残差神经网络(Residual neural network, ResNet)由于其强大的特征提取能力,已广泛应用于辐射源个体识别^[17-18]。因此,本文设计了4种神经网络结构,具体结构如图9、10所示。其中图10(a,b)为残差神经网络的主体结构,图10(c)为其中的残差模块结构,即图10(a,b)中的Resid层,残差结构的设计使得其在增加网络深度的同时,避免了梯度爆炸。本文利用5台无人机的数据对4种网络结构的闭集识别能力进行验证。在神经网络的训练阶段采用自适应调整学习率策略,设置初始学习率为0.003,当验证集的准确率在5个周期内上升幅度一直小于0.001%,则变为原来的0.9倍;当验证集的准确率连续5个周期没有提升时,停止训练。最后保存验证集准确率最高时的模型参数。识别结果如图11所示,因此本文选择识别准确率最高的残差神经网络1作为最终的神经网络结构,作为后续OpenMax改进的基础架构。

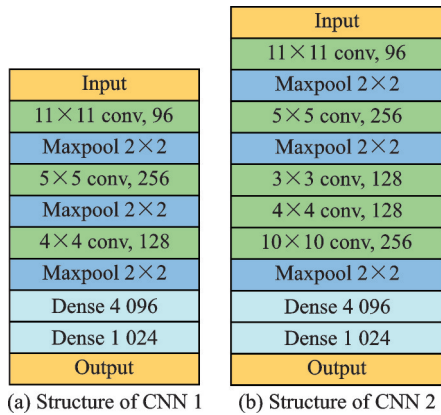


图9 卷积神经网络结构
Fig.9 Structures of CNNs

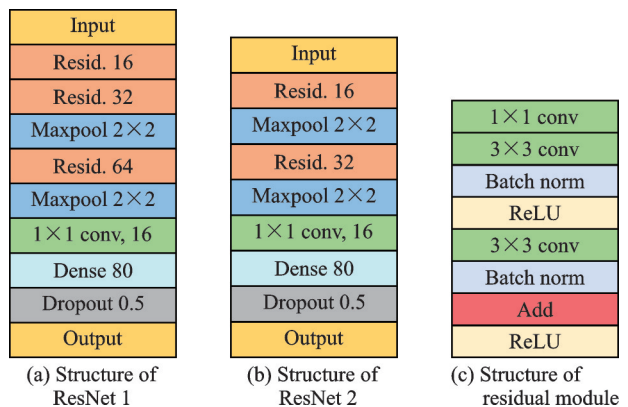


图10 残差神经网络结构
Fig.10 Structures of ResNets

4.4 开集识别性能对比

为了验证所提出的DSTFT和多质心OpenMax以及改进损失函数的作用,本文做了相关消融实验,结果如表2所示。实验设置训练集包含5架无人机数据,测试集包含6台无人机(1台未知无人机)数据,即开放度为0.047。DSTFT、多质心OpenMax和改进损失函数均可以提高无人机开集识别的准确率。

为了进一步验证基于多质心OpenMax的无人机个体开集识别方法的有效性,本文将所提算法与传统OpenMax和文献[19]中的基于KNN(K-nearest neighbor)的开集识别算

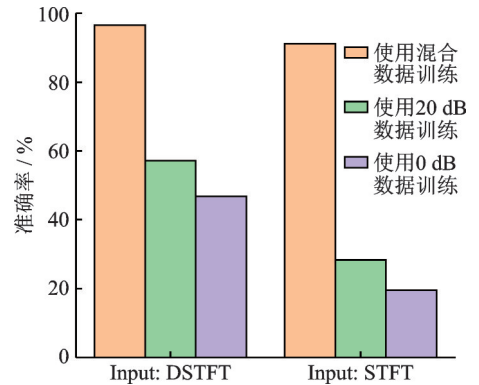


图8 输入特征和训练数据改变时识别准确率对比图
Fig.8 Comparison of identification accuracy when inputting features and training data change

最后保存验证集准确率最高时的模型参数。识别结果如图11所示,因此本文选择识别准确率最高的残差神经网络1作为最终的神经网络结构,作为后续OpenMax改进的基础架构。




图11 不同神经网络结构闭集识别准确率
Fig.11 Identification accuracy of closed sets of different neural network structures

法、以及基于 ResNet 的识别算法相对比。本文验证了模型在不同开放度的识别准确率,训练集中包含的无人机个数固定为 5,测试集中包含的无人机个数分别为 5、6、7、8、9、10,对应的开放度为 0、0.047、0.087、0.123、0.155、0.184。开集识别结果如图 12 所示。在开放度为 0 时,本文所提算法与基于 ResNet 的算法性能相当,说明本文算法在增加开集识别能力时,并未影响网络原先的闭集识别性能。随着开放度的增加,开放空间风险变大,开集识别的准确率也逐渐下降。基于 ResNet 的算法由于不具备开集识别能力,因此测试集中新增的无人机信号样本全部识别错误,识别性能急剧下降。但本文所提方法在开放度 0.184 时,识别准确率仍能达到 91.56%,明显优于 KNN 方法。而且为了不影响历史已知无人机的识别,基于 KNN 的开集识别必须训练两个 KNN 分类器,一个用来检测是否为未知无人机,另外一个用来识别之前已有训练样本的辐射源。本文所提出的多质心 OpenMax 方法是直接将 N 分类识别网络扩展为可识别未知无人机的 $N+1$ 分类器,无需训练两个分类器。

5 结束语

本文针对低空领域信道环境复杂导致无人机开集识别准确率下降的问题,提出了基于多质心 OpenMax 和差值短时傅里叶变换的无人机开集识别方法。该方法通过从信号中提取与信道无关的差值时频特征和数据增强,显著降低了信道环境改变对识别准确率的影响。同时,本文将 OpenMax 改进为多质心 OpenMax,在不影响闭集识别准确率的前提下,进一步提高了开集识别准确率。本文所提算法可在复杂信道环境中进行无人机个体识别的同时检测新的未知辐射源即非法无人机,进一步实现无人机的身份识别,为低空物联网的安全管控提供可行方案。

参考文献:

- [1] 刘志文, 陈旗, 郑恒权, 等. 基于特征融合的通信辐射源个体识别[J]. 数据采集与处理, 2022, 37(6): 1280-1287.
LIU Zhiwen, CHEN Qi, ZHENG Hengquan, et al. Specific identification of communication emitter based on feature fusion[J]. Journal of Data Acquisition and Processing, 2022, 37(6): 1280-1287.
- [2] 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.
- [3] LIU Boyang, ZHANG Haoran, WAN Yiyao, et al. Robust adversarial attacks on deep learning-based RF fingerprint identification[J]. IEEE Wireless Communications Letters, 2023, 12(6): 1037-1041.
- [4] WANG Yu, GUI Guan, GACANIN H, et al. An efficient specific emitter identification method based on complex-valued neural networks and network compression[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2305-2317.
- [5] ZHANG Jingwen, WANG Fanggang, DOBRE O A, et al. Specific emitter identification via Hilbert-Huang transform in single-hop and relaying scenarios[J]. IEEE Transactions on Information Forensics and Security, 2016, 11(6): 1192-1205.
- [6] HANNA S, KARUNARATNE S, CABRIC D. Open set wireless transmitter authorization: Deep learning approaches and dataset considerations[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 59-72.
- [7] 林子榆, 王翔, 孙丽婷, 等. 基于深度自编码器的辐射源个体开集识别[J]. 太赫兹科学与电子信息学报, 2022, 20(12): 1285-1291.

表 2 开放度 0.047 时不同方法开集识别准确率
Table 2 Open set identification accuracy of different methods when the openness is 0.047

方法	准确率/%
STFT+传统 OpenMax	85.21
STFT+多质心 OpenMax	89.07
DSTFT+传统 OpenMax	91.93
DSTFT+多质心 OpenMax+改进损失函数	95.94

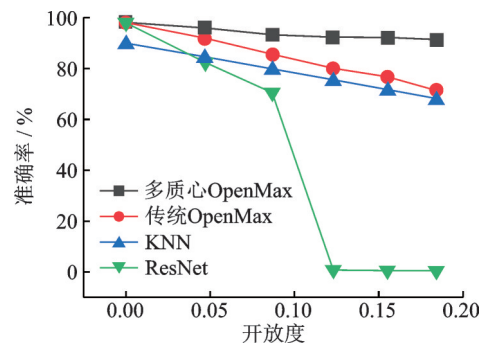


图 12 不同算法开集识别准确率随开放度变化图

Fig.12 Open set identificaion accuracy of different algorithms varying with openness

- LIN Ziyu, WANG Xiang, SUN Liting, et al. Open set recognition of specific emitter identification based on deep auto-encoder [J]. *Journal of Terahertz Science and Electronic Information Technology*, 2022, 20(12): 1285-1291.
- [8] KARUNARATNE S, HANNA S, CABRIC D. Open set RF fingerprinting using generative outlier augmentation[C]// *Proceedings of 2021 IEEE Global Communications Conference*. Madrid, Spain: IEEE, 2021: 1-7.
- [9] 王春升, 王永民, 许华, 等. 面向开集场景的辐射源个体识别[J]. *西安交通大学学报*, 2022, 56(10): 130-140.
WANG Chunsheng, WANG Yongmin, XU Hua, et al. Specific emitter identification under open set scenes[J]. *Journal of Xi'an Jiaotong University*, 2022, 56(10): 130-140.
- [10] 刘人玮, 李天响, 章昕亮, 等. 基于卷积原型网络的通信辐射源个体开集识别方法[J]. *信息工程大学学报*, 2023, 24(2): 140-149.
LIU Renwei, LI Tianyun, ZHANG Xinliang, et al. Open-set emitter identification based on convolutional prototype network [J]. *Journal of Information Engineering University*, 2023, 24(2): 140-149.
- [11] 刘志文, 陈旗, 满欣. 基于SDAE_SVDD的通信辐射源个体开集识别方法[J]. *电子信息对抗技术*, 2023, 38(4): 26-31.
LIU Zhiwen, CHEN Qi, MAN Xin. Individual open set recognition of communication emitter based on SDAE_SVDD[J]. *Electronic Information Warfare Technology*, 2023, 38(4): 26-31.
- [12] WU Yuefeng, SUN Zhuo, GAO Yue. Siamese network-based open set identification of communications emitters with comprehensive features[C]// *Proceedings of 2021 6th International Conference on Communication, Image and Signal Processing (CCISP)*. Chengdu, China: IEEE, 2021: 408-412.
- [13] BENDALE A, BOULT T E. Towards open set deep networks[C]// *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.]: IEEE, 2016: 1563-1572.
- [14] SCHEIRER W J, DE REZEETDE ROCHA A, SAPKOTA A, et al. Toward open set recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(7): 1757-1772.
- [15] GENG Chuanxing, HUANG Shengjun, CHEN Songcan. Recent advances in open set recognition: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(10): 3614-3631.
- [16] 杨雷, 郭恩泽, 刘益岑, 等. 基于轻量级残差网络的无人机个体识别方法[J]. *兵器装备工程学报*, 2023, 44(6): 246-253.
YANG Lei, GUO Enze, LIU Yicen, et al. UAV individual recognition method based on scale down ResNet[J]. *Journal of Ordnance Equipment Engineering*, 2023, 44(6): 246-253.
- [17] SCHEIRER W J, ROCHA A, MICHEALS R J, et al. Meta-recognition: The theory and practice of recognition score analysis [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(8): 1689-1695.
- [18] 许全, 谭守标, 孙翔, 等. 基于1D-CNN-LSTM的特定辐射源识别方法[J]. *现代计算机*, 2022, 28(12): 30-34.
XU Quan, TAN Shoubiao, SUN Xiang, et al. A specific emitter identification method based on 1D-CNN-LSTM[J]. *Modern Computer*, 2022, 28(12): 30-34.
- [19] SHEN G, ZHANG J, MARSHALL A, et al. Towards scalable and channel-robust radio frequency fingerprint identification for LoRa[J]. *IEEE Transactions on Information Forensics and Security*, 2022, 17: 774-787.

作者简介:



杨宁(1996-),女,博士研究生,研究方向:辐射源个体识别、物理层安全,E-mail: corrine_yang@126.com。



胡景明(1978-),男,副教授,研究方向:卫星通信、信号处理等。



张邦宁(1963-),男,教授,博士生导师,研究方向:卫星通信、通信抗干扰技术、辐射源个体识别等。



丁国如(1986-),男,教授,博士生导师,研究方向:数字孪生、信号处理、电磁频谱感知等。



郭道省(1973-),通信作者,男,教授,博士生导师,研究方向:辐射源个体识别、卫星通信、通信抗干扰技术等,E-mail:xyzgfg@sina.com。