

采用残差神经网络的无人机 遥控信号识别监测算法

李彬¹, 徐怡杭², 罗杰²

(1. 西北工业大学电子信息学院, 710072, 西安; 2. 西安交通大学电子与信息学部, 710049, 西安)

摘要: 为了解决无人机遥控信号在识别监测时易受随机噪声、窄带与宽带干扰影响,以及遥控信号跳频序列的跳频周期、跳频速率等特征难以准确提取的问题,提出了一种采用残差神经网络对无人机遥控信号时频谱图进行识别监测的算法(DRN-UAV)。首先通过滑动时间窗来读入时频谱图,并以联合自适应的方法计算信号频谱检测阈值;然后对已读入的时频谱图进行二值化、剔除干扰等预处理操作,构造待测谱图;接着将大量实测的不同机型遥控信号待测谱图作为数据集来训练和测试残差神经网络,进而避免跳频特征难以提取的问题;最终由训练好的网络来实时识别当前遥控信号是否存在及其所属机型。DRN-UAV 算法能克服遮挡及无人机体积等不利影响,是对基于雷达或光学的反无人机系统的有效补充。实验结果表明:DRN-UAV 算法使单次识别耗时约缩短为传统读入方式的 1/25;在相同误检率下,DRN-UAV 算法得到的信号频谱检测阈值相比传统方法降低了 1.4 dBm,在不同硬件平台上都能有效增加检测范围;当信噪比高于 5.5 dB 时,在单个窄带定频信号和 WiFi 干扰下,检测错误率能达到 0.01% 以内。

关键词: 无人机;遥控信号;跳频序列;识别;残差神经网络

中图分类号: TM92 **文献标志码:** A

DOI: 10.7652/xjtuxb202112017 **文章编号:** 0253-987X(2021)12-0146-09



OSID 码

A Recognition and Monitoring Algorithm for Drone Remote Control Signals Using Residual Neural Network

LI Bin¹, XU Yihang², LUO Jie²

(1. School of Electronics and Information, Northwest Polytechnical University, Xi'an 710072, China;

2. Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: An algorithm to monitor the control signal of drone using residual neural network is proposed to solve the problems that remote control signals of unmanned aerial vehicles (UAV) are usually susceptible to random noise and narrowband or broadband interference, and it is difficult to extract the frequency hopping period and rate of frequency hopping sequence of a remote control signal. Firstly, a time-spectrogram is obtained via a sliding time window, and a threshold of signal spectrum detection is calculated by a joint adaptive method. Then, pre-processing operations such as binarization and interference elimination are performed on the time-spectrogram to construct the time spectrum to be measured. Further, a large number of processed spectrograms of different control signals are used as a data set to train and test the deep residual neural network, so as to avoid the problem of difficult extraction of frequency hopping

收稿日期: 2021-04-21。 作者简介: 李彬(1983—),男,博士,副教授。 基金项目: 国家重点研发计划资助项目(2020YFB1807004,2020YFB1807003)。

网络出版时间: 2021-09-02

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20210902.1421.004.html>

features. Finally, the trained network is used to recognize the current remote control signal and its model in real time. The proposed DRN-UVA algorithm overcomes the adverse effects such as occlusion and UVA size, and is an effective supplement to anti-UVA system based on radar or optics. Experimental results show that the DRN-UAV algorithm shortens the single recognition time to about 1/25 of the traditional reading method. At the same error detection rate, the signal spectrum detection threshold obtained by the DRN-UAV algorithm reduces by 1.4 dBm compared with that of the traditional method and the detection range is effectively increased on different hardware platforms. When the signal-to-noise ratio is higher than 5.5 dB, the detection error rate can reach less than 0.01% under the interferences of single narrowband fixed-frequency signal and WiFi.

Keywords: drone; remote control signal; frequency hopping sequence; recognition; residual neural network

近年来,无人机的快速发展与普及,在给人民生活带来便利的同时,也出现了越来越多的“黑飞”事件,给国家和公众都带来了安全隐患和经济损失。2017年4月,成都双流机场有无人机非法入侵跑道,造成诸多航班停飞,带来了巨大的经济损失;2018年8月4日,委内瑞拉总统马杜罗在公开演讲时,被绑有炸药的民用无人机袭击;2019年9月14日,沙特两处石油设施遭到无人机袭击,量产减半;2021年2月22日,重庆轨道交通2号线遭无人机撞击逼停^[1-3]。如何反制无人机非法入侵的问题越来越受到各国的重视,而快速精确地识别无人机是实现反制的关键。

雷达低空监测无人机成本高昂,难以大规模部署,且由于其监测盲区较大、民用无人机体积过小,极易造成漏警;光学识别无人机易受光强、云雾、遮挡等干扰,且在夜间监测效果较差;声纹识别无人机监测距离过短,且不适用于嘈杂的城市环境中^[4-6];而利用无线电频谱监测无人机遥控信号则成本较低、不受光强、云雾、遮挡、无人机体积等不利因素的影响,是对反无人机系统的有效补充。

一种解决方案是直接监测从1 MHz~6.8 GHz的广泛频谱,并将检测到的任何未知射频信号当作无人机控制信号^[7],但由于未知的射频信号不一定是无人机控制信号,这种方法会导致较高误报概率。识别无人机的媒体访问控制(MAC)地址也是一个可行的方法^[8],但此方法仅能够检测具有MAC地址的无人机,且随着无人机种类的不断增加,构建和更新无人机MAC地址的完整数据库变得越来越困难。此外,为了避免被检测到,无人机的MAC地址往往具有欺骗性。

识别无人机遥控信号谱图则是一个有效的解决

方案。民用无人机遥控信号主要采用跳频扩频(frequency hopping spread spectrum, FHSS),属于非平稳信号,可通过短时傅里叶变换 STFT 方法,将天线、接收机采集到的多个时刻的信号变换成信号谱图^[9-11]。无人机遥控信号带宽通常小于3 MHz,常在以2.44 GHz为中心频率的附近100 MHz频带内跳变^[12],而5.775 GHz附近100 MHz的频段有时也会被用于遥控,如大疆精灵III型无人机的遥控信号,其遥控信号带宽约为1 MHz^[13]。

利用短时傅里叶变换将跳频扩频的无人机遥控信号转换为谱图后,就近似地将其等价为对于跳频序列谱图的识别问题。有许多学者曾研究过如何提取跳频序列的跳频特征^[14-16],包括检测跳频序列周期、跳频速率^[17-18]等,或采用小波分解^[19]、HOG-SVM^[20]方法来识别跳频序列,但实际的无人机遥控信号功率通常较小,当距离较远时,受天线、接收机性能约束,可能造成跳频序列捕捉不完整,传统的跳频特征提取方法难以适用,也难以通过提取到的跳频特征判断机型。此外,由于遥控信号功率较小,且背景噪声会随时间与场景变化,就要求遥控信号的频谱检测阈值,在低虚警概率下尽可能贴近背景噪声,同时必须是自适应的,而无人机遥控信号常用的2.4 GHz与5.8 GHz频段频谱环境复杂,容易受到WiFi以及窄带突发信号的干扰^[21-22],所以如果要在工程中应用,算法须具有较强的鲁棒性。

对此,本文提出了一种采用残差神经网络的无人机遥控信号识别监测算法(DRN-UAV),通过联合自适应信号检测阈值计算改进现有的阈值计算方法,并通过预处理操作来对抗窄带与宽带干扰,最后利用残差神经网络识别是否存在及其机型。本文算法具有良好的鲁棒性与工程应用价值。

1 无人机遥控信号识别监测方法

无人机单次识别的流程如图 1 所示,重复该步骤即可实现连续识别。




图 1 无人机单次识别的流程图
Fig. 1 Flow chart of single recognition

DRN-UAV 算法流程如下:①由谱图 M_i ($M_i \in \mathbf{R}^{N \times S}$) 计算出联合自适应信号检测阈值 A_{th} ,同时将谱图 M_i 映射为二值化谱图 M_a ($M_a \in \{0,1\}^{N \times 100}$);②将二值化谱图 M_a 中的宽带干扰所在频点置零后抽出非零帧,由前 100 帧非零帧得到分辨率为 100×100 的待测谱图 M_d ($M_d = \{0,1\}^{100 \times 100}$),不足 100 帧时用全零帧补足;③用得到的待测谱图 M_d 训练神经网络;④通过已训练好的残差神经网络 ResNet-34,识别出当前无人机是否存在及其机型。

1.1 采集无人机遥控信号时频谱图 M_i

采用图 2 所示的无人机遥控信号识别系统对中心频率 f_c 附近 100 MHz 带宽(共 S 个频点)进行 N 次连续的频谱快照,形成具有 N 帧的单张谱图 $M_i \in \mathbf{R}^{N \times S}$ 。因实验设备无法一次性扫描 100 MHz 带宽,故将连续采集的多段相邻频率的频谱拼接成 100 MHz,以此作为单次频谱快照。滑动读入谱图



图 2 本文采用的无人机遥控信号识别系统
Fig. 2 Drone remote control signal recognition system adopted in this paper

M_i 示意如图 3 所示,其中 $n=50, N=20n$ 。




图 3 滑动读入谱图 M_i 示意图
Fig. 3 Swipingly reading the time-spectrogram M_i

1.2 数据预处理

数据预处理包括计算联合自适应阈值 A_{th} 、二值化谱图 $M_a \in \{0,1\}^{N \times 100}$ 以及构造待测谱图 $M_d \in \{0,1\}^{100 \times 100}$ 这 3 个步骤。

1.2.1 计算联合自适应阈值 A_{th} 现有的阈值计算方法有通过经验人工设定阈值,但这样的固定阈值往往难以适应复杂多变的电磁环境,且若阈值设定过高,则漏警率会上升,设定过低,则虚警率会上升。要使漏警率与虚警率保持在较低水平,需要一个合理的动态更新的阈值计算方法,在文献[23]中,杨亚南通过计算出底噪的均值与方差,在恒定虚警率的条件下,计算下一段的阈值 A_{th}^*

$$A_{th}^* = E - \sqrt{2}\sigma \text{erf}^{-1}(1 - 2P) \quad (1)$$

式中: E 为均值; σ 为标准差; $\text{erf}(x)$ 为误差函数; P 为恒定的虚警概率。但该方法不适用于复杂的电磁环境,会导致较多噪声在检测阈值之上,对无人机信号谱图造成较大污染。

本文提出了一种新的联合自适应阈值计算方法,在可接受的虚警概率范围内,最大限度的将漏警率降到最低,即计算出的检测阈值最低,尽可能贴近底噪,同时让绝大部分噪声低于信号检测阈值。方法基本思路是采用两种不同的阈值计算方法,最后取较低的阈值作为最后的检测阈值 A_{th} ,该方法的优点是计算出的检测阈值兼有较高的稳定度与精确度。

方法一 在本课题组之前发表的论文^[24]中提出了利用二次求平均值的方法计算检测阈值,主要思路是先计算当前帧的第一次均值 E_1 与标准差 σ_1 。

计算粗检测阈值 A_{th}^{rough}

$$A_{th}^{\text{rough}} = E_1 + 2\sigma_1 \quad (2)$$

然后,继续对该帧数据进行计算。在计算第二次的

均值 E_2 与标准差 σ_2 时,数值高于粗检测阈值 A_{th}^{rough} 的频点不参与运算。

计算细检测阈值 $A_{th}^{accurate}$

$$A_{th}^{accurate} = E_2 + 2\sigma_2 \quad (3)$$

最后对单张谱图 $\mathbf{M}_t$ 中的 N 帧数据得到的 N 个细检测阈值 $A_{th}^{accurate}$ 进行线性拟合,并取其中点对应的值为检测阈值 A_{th}^1 。

方法二 依次记录单张谱图 $\mathbf{M}_t$ 中 N 帧数据的 N 个最大值,构成向量 $\mathbf{m} \in \mathbf{R}^{N \times 1}$ 。对 $\mathbf{m}$ 进行 7 点的滑动中值滤波后得到 $\mathbf{m}^*$,再将 $\mathbf{m}^*$ 的 N 个值线性拟合,同样将拟合直线中点对应的值作为的检测阈值 A_{th}^2 。联合自适应阈值 A_{th} 计算式如下

$$A_{th} = \min\{A_{th}^1, A_{th}^2\} \quad (4)$$

每秒更新一次 A_{th} 。方法一的优点是计算出的检测阈值 A_{th}^1 稳定,受到如 WiFi 等较宽带宽的信号影响较小,但还不够精确地贴近底噪;方法二的优点是计算出的检测阈值 A_{th}^2 贴近底噪,较为精确,但如果长时间存在定频信号干扰,则可能导致较大的阈值计算误差,进而影响检测效果。方法二的原理是大量实验中发现,无论是无人机遥控信号还是 WiFi 信号的二值化谱图,其中的非零帧均不超过 $N/4$,所以大多数帧中的最大值即为该帧底噪的峰值,只有少数帧的最大值为待测信号的峰值,通过 7 点的最小值滤波器后,剩下的便是不同帧的底噪峰值。

方法一与方法二联合求解取最小值后,可在保证检测阈值精度的同时也保证其稳定性,即联合自适应检测阈值计算。

1.2.2 二值化谱图 $\mathbf{M}_a$ 以对抗随机噪声与杂散信号 文献[24]中提出了一种基于谱图峰值寻找与带宽计算的映射方法,该方法的好处是能够精确计算出窄带信号的带宽,但无法测得 Wifi 等宽带信号的峰值与带宽,而本文算法中二值化谱图 $\mathbf{M}_a$ 带宽分辨率为 1 MHz,对带宽精度要求不高。为简化运算,本文改为对每 1 MHz 带宽进行一一检索的方法,从而实现二值化映射。

(1) 对抗随机噪声。将谱图 $\mathbf{M}_t$ 高于阈值 A_{th} 的频点置为 1,其他频点置为 0。

(2) 对抗杂散信号。首先,计算出 $\mathbf{M}_t$ 中每 1 MHz 所包含的频点总数 $S_{1 \text{ MHz}}$

$$S_{1 \text{ MHz}} = \left\lceil \frac{S}{100} \right\rceil \quad (5)$$

然后,初始化 $\mathbf{M}_a$ 为全零矩阵,统计出当前帧(记为第 i 帧, $1 \leq i \leq N$)第 j MHz 中数值高于检测阈值 A_{th} 的频点数,记为 h_j ,并按照如下规则进行映射

$$\begin{aligned} M_{a_{ij}} &= 1 \\ \text{s. t. } \frac{h_j}{S_{1 \text{ MHz}}} &\geq 0.3 \end{aligned} \quad (6)$$

具体映射过程如图 4 所示。重复上述步骤,遍历 $\mathbf{M}_t$ 即可将其映射为二值化谱图 $\mathbf{M}_a$ 。




图 4 二值化映射示意图

Fig. 4 Binarization mapping

由于杂散信号带宽极窄,而无人机遥控信号带宽大于 0.3 MHz,进一步增强了算法的鲁棒性。

1.2.3 构造待测谱图 $\mathbf{M}_d$ 以对抗宽带干扰 WiFi 宽带干扰往往不会充满所有时刻,故可将 WiFi 干扰直接从检测其存在的频谱快照中剔除。

(1) 剔除二值化谱图 $\mathbf{M}_a$ 中连续的“1”:首先构造一个与二值化谱图大小相同的全零谱图 $\mathbf{M}_a^*$,对二值化谱图 $\mathbf{M}_a \in \{0, 1\}^{N \times 100}$ 逐帧遍历。

如图 5 所示,每当检测到该帧频谱快照某频点值为“1”,就统计从该频点开始的 B MHz 内(共计 B 个频点)所包含 1 的数量 z ;若 $z < B-1$,则可以认为该频点上的信号属于窄带信号,将构造好的 $\mathbf{M}_a^*$ 上对应的频点置为 1;若 $z \geq B-1$,则认为在该频点上发现 WiFi 干扰信号,不变更 $\mathbf{M}_a^*$,继续向后遍历直到出现 $z < B-1$,认为 WiFi 信号结束,跳过 B 个频点继续向下一个频点遍历,其中 $B=5$ 。




图 5 二值化谱图 $\mathbf{M}_a$ 与 $\mathbf{M}_a^*$ 的映射关系

Fig. 5 Mapping relationship between $\mathbf{M}_a$ and $\mathbf{M}_a^*$

(2) 将 $\mathbf{M}_a^*$ 中的非零帧抽取出来,取前 100 帧非零帧构造待测谱图 $\mathbf{M}_d \in \{0, 1\}^{100 \times 100}$,若不足 100 帧由全零帧补足,待测谱图 $\mathbf{M}_d$ 可用于训练残差神经

网络。至此,二值化谱图 $\mathbf{M}_a$ 中的带宽超过 4 MHz 的宽带干扰信号都被滤除。

1.3 用待测图谱 $\mathbf{M}_d$ 训练残差神经网络

卷积神经网络具有优异的分类性能,且随着各层神经元个数的增加,或层数的加深,网络性能往往能得到有效提升,深层网络一般会比浅层网络效果更好^[25]。更深的网络能学习到更加复杂的表达,更宽的网络则意味着每一层映射能力会增强,但对网络整体性能的提升有限。由于不同型号的无人机遥控信号的谱图都存在差异,且随着数据集中无人机机型的完善,需要神经网络具有足够的分类能力,故选择采用更深层网络。而神经网络深度超过了一定层数后性能反而会出现退化,残差神经网络则是一个有效的解决方案^[26]。残差块定义如图 6 所示。




图 6 残差块的定义

Fig. 6 Definition of residual block

图 6 中 $F(x)$ 表示残差函数,记网络输出函数 $H(x) = F(x) + x$,可得到

$$H(x) = F(x, \{W_i\}) + W_s x \quad (7)$$

式中: $F(x, \{W_i\})$ 可表示 x 通过多个卷积层; W_s 是为了保证(6)式中 $F(x, \{W_i\})$ 与 x 维度相同而做的线性变换。由于残差块的组成包括两个隐层,可得

$$H(x) = W_2 \sigma(W_1 x) + W_s x \quad (8)$$

式中, σ 代表 Relu 函数

$$\text{Relu}(x) = \max(0, x) \quad (9)$$

残差神经网络 ResNet34 主要由基本单元 I (残差块)、基本单元 II (下采样残差块) 构成,如图 7、图 8 所示。

对于图 7、图 8 中 3×3 卷积核,记输入矩阵为




图 9 ResNet-34 结构图

Fig. 9 Structure of ResNet-34 network




图 7 ResNet-34 的基本单元 I

Fig. 7 The basic unit I of ResNet-34




图 8 ResNet-34 的基本单元 II

Fig. 8 The basic unit II of ResNet-34

x , 单次卷积的输出结果为 $u_{i,j}$, 其计算公式如下

$$u_{i,j} = \sum_{m=0}^{3-1} \sum_{n=0}^{3-1} w_{m,n} x_{i+m,j+n} \quad (10)$$

式中: w 为卷积核权重; 下标 i, j 与 m, n 都分别表示行、列号。

神经网络识别遥控信号可避免跳频周期、速率等特征难以准确提取的问题。而加入残差结构能克服深层网络性能退化的现象,增强网络的分类和泛化能力,适用于多机型的遥控信号识别。

图 9 为 ResNet34 网络的结构图。其中, Pool 代表 2×2 的最大池化层, Avg pool 指平均池化层, F_c 是全连接层, $\text{Conv}(3 \times 3, d)$ 代表卷积核大小为 3×3 的卷积层, $d=64, 256, 128, 512$ 代表了通道数。网络包括 16 个残差结构和 2 个池化层,总计 34 层。

2 实验

本文测试系统由天线、接收机及笔记本电脑组

成,选取了大疆精灵 III、九鹰、Futaba T14SG、天地飞 07 等几种国内常见型号的无人机遥控器,采用本文算法进行识别验证,测试场景如图 10 所示。

实验中,系统连续扫描 100 MHz 带宽频谱(单次最大扫描带宽为 20 MHz,本实验将连续 5 个时刻的相邻的 20 MHz 频谱拼接),中心频率依次选择为 2.44 GHz 与 5.775 GHz。实验结果表明,在 50、25、1 kHz 的频谱分辨率带宽下本文算法均能较为准确地识别到无人机遥控信号及其型号。此外,在信号发射源产生窄带突发干扰、路由器产生 WiFi 宽带干扰下,本文算法均取得了较好的识别效果,证明算法具有较强的鲁棒性。



图 10 多型无人机遥控器测试场景

Fig. 10 Test scenes of multi-type drone remote controllers

图 11 展示了联合自适应阈值计算法的实验结果,根据实测数据比较了阈值计算方法一(利用二次求平均值)、方法二(基于最小值滤波器)、方法三(基于中值滤波器)计算出的阈值结果。从图 11 可以看出阈值计算方法二在保证错误率相同的情况下,利用最小值滤波器求出来的阈值更贴近底噪。但阈值计算方法二在捕捉到遥控信号较为密集时,其阈值计算结果可能不够稳定。方法一则相较于方法二更稳定。

联合阈值计算方法一与方法二求解,能够使阈值足够贴近底噪,且具有较强的鲁棒性。

以大疆精灵 III 型无人机遥控信号实测数据为例,图 12a 是由 $N=1\,000$ 次频谱快照形成的包含 $S=2\,381$ 个采样频点的 100 MHz 频带。图 12b 则表




图 11 不同方法的阈值计算结果比较

Fig. 11 Comparison of different methods in threshold calculation

示抽取 $N=100$ 次包含遥控信号的频谱快照形成的 100 MHz 频带,有 $S=100$ 个采样频点。





图 12 大疆精灵 III 型遥控器实测结果


Fig. 12 Test results of DJI Phantom III remote controller signals

对比图 12a、12b 不难看出,经过预处理后的待测谱图 M_d 特征更为明显,随机噪声以及定频、宽带干扰都被有效压制,相较于原始的谱图 M_t 更易于识别到无人机遥控信号。

宽带干扰的谱图预处理结果如图 13 所示,图 13a 是大小为 100×100 的 WiFi 信号二值谱图(由捕捉到的 50 余帧 WiFi 信号频谱快照构成),图 13b 为将图 13a 剔除宽带干扰后构成的待测谱图 M_d 。其中,横坐标 1~100 分别代表 100 相邻个频点,纵坐标则依次代表 100 个时刻的频谱快照,亮点代表该频点值为 1,其余频点值为 0。



(a)剔除全零帧后 WiFi 信号的二值谱图



(b)WiFi 干扰信号的待测谱图 M_d 示意图

图 13 实测中对抗 WiFi 干扰的效果

Fig. 13 Results of filtering WiFi interference in real environments

从图 13 可以看出在检测信号时,宽带干扰信号的谱图通过预处理后,基本得到剔除,对无人机遥控信号检测影响较小。而对于包含定频或突发窄带干扰的谱图,在预处理后对无人机遥控信号检测基本不构成影响。

通过对包含不同类型无人机遥控信号以及包含宽带干扰、突发窄带干扰、定频干扰的谱图 M_i 预处理后,得到由多类待测谱图 M_d 构成的数据集,即 UAV-STFT 数据集。本次实验中训练集共包含 1 980 个样本,验证集 443 个样本,测试集 500 个样本。图 14a、b、d 分别展示了两两种机型与预处理前后 WiFi 干扰信号的训练样本。

用一位有效编码规则为 UAV-STFT 数据集制作多类标签。用标记好的数据集训练方法中的给出的经预训练的 34 层残差神经网络,优化算法使用 Adam,经多次迭代后,ResNet34 网络的训练结果如图 15 所示。

由于现阶段采集到的用于训练的无人机遥控信号种类还较少,网络较好地完成了分类任务。整个训练集损失和测试集损失也是一直在呈现明显下降

的趋势,说明网络没有出现拟合。若需要识别更多的机型,可扩大 UAV-STFT 数据集,新增更多的无人机遥控信号类型标签,然后在原先网络的基础上继续训练,微调网络参数。ResNet 残差神经网络具有较好的多分类效果,适用于解决多类无人机遥控信号分类。



(a)大疆精灵 III 的训练样本



(b)九鹰的训练样本



(c)预处理前的 WiFi 信号训练样本



(d)预处理后的 WiFi 信号训练样本

图 14 UAV-STFT 训练集部分样本展示

Fig. 14 Part of the UAV-STFT training set data




图 15 ResNet-34 训练结果

Fig. 15 Training results of ResNet-34

在频谱分辨率带宽为 25 kHz、中心频率为 2.44 GHz,在 0~10 dB 范围的信噪比下,连续采集大量的九鹰、大疆精灵 III 型无人机遥控信号实测数据进行测试,最终拟合计算出信噪比与检测成功率的曲

线,如图 16 所示。




图 16 2 种无人机的信噪比与检测成功率关系曲线

Fig. 16 Curves of detection success rate versus SNR for 2 types of UAV

识别过程中干扰信号强度对检测算法没有直接影响,干扰增强主要是通过增强底噪,进而影响阈值计算,最后间接影响本文提出的算法。如果识别过程中干扰信号增强没有抬升底噪,则基本不影响阈值计算,经过二值化后,干扰将被剔除。

3 结 论

本文提出了一种采用残差神经网络来识别无人机遥控信号的算法,并搭建原型机系统测试。首先通过滑动时间窗来读入时频谱图,并以联合自适应的方法计算信号频谱检测阈值;然后对已读入的时频谱图进行二值化、剔除干扰等预处理操作,构造待测谱图;接着将大量实测的不同机型遥控信号待测谱图作为数据集来训练和测试残差神经网络。最终由训练好的网络实时识别当前遥控信号是否存在及其所属机型。

(1)滑动地读入谱图,每更新 20 帧频谱数据便可得到当前新的识别结果,耗时仅为原先单次识别的 1/25。而直接处理谱图计算量过于庞大,本文地将谱图抽象为二值化的待测谱图,变成了 1 万个二值频点,极大地简化了运算。

(2)所提出的联合自适应阈值计算,满足了动态更新的特性,并在保证阈值计算稳定性的同时,增加了计算的精确性。在相同误检率下,DRN-UAV 算法得到的信号频谱检测阈值相比传统方法降低了 1.4 dBm。

(3)本文算法的通过生成二值化谱图与待测谱图使算法和系统具有较强的鲁棒性,当信噪比高于 5.5 dB 时,在单个窄带定频信号和 WiFi 干扰下,检测错误率能达到 0.01% 以内。

参考文献:

[1] 张召忠. 无人机携炸弹袭击委总统,谁干的? [N]. 科技日报, 2018-08-08(5).

[2] 杨慧君. 沙特油田遇袭:低慢小目标防御是难点 [N]. 中国航天报, 2019-10-12(1).

[3] 张静, 张科, 王靖宇, 等. 低空反无人机技术现状与发展趋势 [J]. 航空工程进展, 2018, 9(1): 1-8, 34. ZHANG Jing, ZHANG Ke, WANG Jingyu, et al. Status and development trend of low-altitude anti-UAV technology [J]. Advances in Aeronautical Science and Engineering, 2018, 9(1): 1-8, 34.

[4] SHIN H, CHOI K, PARK Y, et al. Security analysis of FHSS-type drone controller [C]//16th International Workshop on Information Security Applications. Berlin, Germany: Springer Verlag, 2016: 240-253.

[5] HOLUBNYCHYI A G, KONAKHOVYCH G F. Spread-spectrum control channels for UAV based on the generalized binary Barker sequences [C]//2013 IEEE 2nd International Conference on Actual Problems of Unmanned Air Vehicles Developments Proceedings. Piscataway, NJ, USA: IEEE, 2013: 99-103.

[6] TOPIC D, MALARIC K, MUMA D. Behavior of 2.4 GHz unmanned aerial vehicle (UAV) under interference [C]//2018 First International Colloquium on Smart Grid Metrology. Piscataway, NJ, USA: IEEE, 2018: 1-4.

[7] TIM F. Domestic drone countermeasures [EB/OL]. [2021-04-17]. <http://www.ddcountermeasures.com/products.html>.

[8] PEACOCK M, JOHNSTONE M N. Towards detection and control of civilian unmanned aerial vehicles [EB/OL]. [2021-03-04]. <https://ro.ecu.edu.au/cgi/viewcontent.cgi?referer=https://sc.panda321.com/&httpsredir=1&article=1051&context=isw>.

[9] KIL H B, LEE J S, JEONG E R. Analysis of frequency hopping signals in commercial drones [J]. International Journal of Pure and Applied Mathematics, 2018, 118(19): 2015-2024.

[10] 刘丽. 民用无人机跳频信号分析与识别技术研究 [D]. 北京: 北京邮电大学, 2019: 29-33.

[11] 陈增茂, 程功, 孙志国, 等. 基于短时傅里叶变换的跳频信号频谱感知性能分析 [J]. 哈尔滨工程大学学报, 2021, 42(6): 902-907. CHEN Zengmao, CHENG Gong, SUN Zhiguo, et al. Performance analysis of spectrum sensing of frequency-hopping signals under fading channels [J]. Journal of Harbin Engineering University, 2021, 42(6): 902-907.

[12] ALIPOUR F A, DABAGHCHIAN A, WANG N, et al. Machine learning-based delay-aware UAV detection and operation mode identification over encrypted Wi-Fi

- traffic [J]. IEEE Transactions on Information Forensics and Security, 2020, 15: 2346-2360.
- [13] MORITO T, SUGIYAMA O, KOJIMA R, et al. Partially shared deep neural network in sound source separation and identification using a UAV-embedded microphone array [C]//2016 IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway, NJ, USA; IEEE, 2016: 1299-1304.
- [14] OLYAEI M H, JALALI H, NOORI A, et al. Fault detection and identification on UAV system with CIT-FA algorithm based on deep learning [C]//26th Iranian Conference on Electrical Engineering. Piscataway, NJ, USA; IEEE, 2018: 988-993.
- [15] ZHAO J C, FU X R, YANG Z K, et al. UAV detection and identification in the internet of things [C]//2019 15th International Wireless Communications & Mobile Computing Conference. Piscataway, NJ, USA; IEEE, 2019: 1499-1503.
- [16] ZHANG H, CAO C, XU L, et al. A UAV detection algorithm based on an artificial neural network [J]. IEEE Access, 2018, 6: 24720-24728.
- [17] 颜雨, 闫晓峰, 吴治霖. 一种复杂环境中跳频信号检测和参数估计改进方法 [J]. 通信技术, 2020, 53(3): 572-577.
- YAN Yu, YAN Xiaofeng, WU Zhilin. Modified method for FH signal detection and parameter estimation in complex environment [J]. Communications Technology, 2020, 53(3): 572-577.
- [18] ATAPATTU S, TELLAMBURA C, JIANG Hai. Spectrum sensing via energy detector in low SNR [C]//Proceedings of the 2011 IEEE International Conference on Communications. Piscataway, NJ, USA; IEEE, 2011: 1-5.
- [19] 张萌, 王文, 任俊星, 等. 基于 HOG-SVM 的跳频信号检测识别算法 [J]. 信息安全学报, 2020, 5(3): 62-77.
- ZHANG Meng, WANG Wen, REN Junxing, et al. Detection and recognition algorithm for frequency hopping signals based on HOG-SVM [J]. Journal of Cyber Security, 2020, 5(3): 62-77.
- [20] 郑洋, 陈西豪, 朱锐, 等. 基于小波分解与希尔伯特-黄变换的跳频信号检测 [J]. 传感器与微系统, 2017, 36(9): 132-135.
- ZHENG Yang, CHEN Xihao, ZHU Rui, et al. Frequency hopping signals detection based on wavelet decomposition and HHT [J]. Transducer and Microsystem Technologies, 2017, 36(9): 132-135.
- [21] EZUMA M, ERDEN, F, KUMAR A C, et al. UAV communications for 5G and beyond [M]. Hoboken, USA; Wiley Online Library, 2020: 71-102.
- [22] NEMER I, SHELTAI T, AHMAD I, et al. RF-based UAV detection and identification using hierarchical learning approach [J]. Sensors, 2021, 21(6): 1947.
- [23] 杨亚南. 无人机信号的侦收与识别方法研究 [D]. 成都: 电子科技大学, 2018: 54-72.
- [24] 陈君胜, 杨小勇, 徐怡杭. 基于遥控信号频谱特征的无人机识别算法 [J]. 无线电工程, 2019, 49(2): 101-106.
- CHEN Junshen, YANG Xiaoyong, XU Yihang. UAV recognition algorithm based on spectrum characteristics of remote control signal [J]. Radio Engineering, 2019, 49(2): 101-106.
- [25] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [26] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision & Pattern Recognition. Piscataway, NJ, USA; IEEE Computer Society, 2016: 770-778.

(编辑 刘杨)