

多无人机强弱信号混叠下的检测与识别方法

王加琪，王 威

(南京航空航天大学电子信息工程学院,南京 211106)

摘要:由于不同无人机(Unmanned aerial vehicle, UAV)的距离差异,混叠信号往往具有不同的信噪比,且低空环境下存在各类干扰信号,进一步增加了识别的难度。针对上述问题,本文提出了多无人机混叠信号下的联合检测-分离-识别方案,该方案通过信号检测、信号分离和信号识别3个步骤,有效提升了不同信噪比混叠信号的检测与识别性能。首先,采用YOLO检测器在时频图上定位潜在无人机信号,在此基础上,提出了一种基于随机偏差的数据增强方法,以降低信号分离过程中的偏差。接着,利用YOLO分类器提取信号的带宽与持续时间特征,完成不同无人机信号的分类。最后,为进一步提高同型号无人机信号识别的精度,提出了加入注意力机制的ResNet模型和优化的Bagging集成学习方法。基于公开数据集的实验结果表明,所提方案在干扰信号与同型号无人机共存场景下的识别性能优于已有方案。

关键词: 无人机检测;无人机识别;混叠信号分离;数据增强;Bagging集成学习

中图分类号: TN925 **文献标志码:**A

Detection and Identification Method for Multiple UAVs with Mixed Strong Weak Signals

WANG Jiaqi, WANG Wei

(College of Electronic and Information Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China)

Abstract: Due to the varying distances of different unmanned aerial vehicles (UAVs), the overlapping signals often exhibit different signal-to-noise ratios, and the presence of various interference signals in low-altitude environments further increases the difficulty of identification. To address these problems, this paper proposes a joint detection-separation-identification scheme for overlapping signals from multiple UAVs. The scheme effectively improves the detection and identification performance of overlapping signals with different SNRs through three steps: signal detection, signal separation, and signal identification. First, the YOLO detector is employed to locate potential UAV signals on the time-frequency spectrogram. Then, a data augmentation method based on random deviation is proposed to mitigate the bias in the signal separation process. Subsequently, the bandwidth and duration features of the signals are extracted using a YOLO-based classifier to achieve classification of distinct UAV signals. Finally, to further improve the recognition accuracy of signals from identical UAV models, an enhanced ResNet model integrated with attention mechanisms and an optimized Bagging ensemble learning method are proposed. Experimental

基金项目:国家自然科学基金(62371231);江苏省前沿引领技术基础研究重大项目(BK20222001);江苏省重点研发计划项目(BE2023027)。

收稿日期:2025-05-13; **修订日期:**2025-10-09

results based on publicly available datasets demonstrate that the proposed scheme outperforms existing methods in scenarios where interference signals and UAVs of the same model coexist.

Key words: unmanned aerial vehicle (UAV) detection; UAV identification; overlapping signal separation; data augmentation; Bagging ensemble learning

引　　言

随着低空经济的迅速发展,无人机在物流、巡检、环境监测和城市治理等领域得到广泛应用^[1-3]。然而,无人机应用范围和规模的扩大使得空域管理和无人机规划等更加复杂,加之无人机飞行审批制度和监管手段不健全等导致无人机黑飞事件频繁发生^[4],严重影响了低空安全并制约低空经济的发展。因此,迫切需要完善低空无人机监管手段^[5-6],确保无人机安全有序飞行。

对无人机身份的精准识别是实现无人机监管的重要前提。然而,低空无人机体积小、质量轻、飞行速度慢且背景复杂,导致无人机识别面临众多挑战。首先,低空无人机的小尺寸和低散射特性使得其雷达回波强度较弱,难以被有效检测^[7]。其次,光学或激光探测设备受设备本身性能和照明条件影响较大,导致成像质量不稳定,尤其是在有建筑遮挡的环境中难以实现无人机的可靠检测^[8]。另外,城市场景中的高功率噪声也会淹没微弱的无人机振动信号,导致无法有效利用声学特征检测无人机^[9]。相比之下,无线信号在复杂环境中稳定性较高,且不易受光照、遮挡等外部条件的影响,因此,基于无线信号的无人机识别方法^[10]受到了越来越多研究者的青睐。

文献[11]从无人机信号的变分模式分解中提取高阶统计特征,采用有向无环图支持向量机对无人机进行识别。文献[12]采用短时傅里叶变换(Short-time Fourier transform, STFT)对无人机信号进行时频变换,得到时频-能量分布特征向量。为了降低特征向量的维数,从而减少低相关度特征对信号识别的影响,其在信号特征子空间变换中应用了主成分分析进行特征降维。文献[13]针对Wi-Fi和蓝牙信号干扰下的无人机信号识别问题,设计了一种用于识别无人机无线信号的双层探测器。探测器从无人机信号中提取了15个瞬态能量特征,并应用邻域分量分析以得到相关度最高的3个特征。结果表明其不仅能识别不同型号的无人机,而且对同型号的无人机也有较高识别精度。

上述传统的机器学习方法为基于特征的无人机信号识别提供了基础,但是基于特征的方案依赖于专家经验来提取特征,特征的好坏直接影响识别效果。随着深度学习的兴起,越来越多的研究者开始关注基于数据驱动的无人机信号识别^[14]。文献[15]针对具有相同带宽的无人机信号与Wi-Fi信号间的识别问题,将信号的31种特征参数输入神经网络进行识别,与传统机器学习算法相比,识别率有小幅提升。文献[16]将无人机信号分解为16个固定边界经验小波子带信号,通过轻量级深度卷积神经网络(Convolutional neural network, CNN)模型对15种不同的商用无人机进行了识别。文献[17]利用正交频分复用(Orthogonal frequency-division multiplexing, OFDM)信号的归一化循环前缀相关谱,结合CNN完成了对无人机的鲁棒性识别。文献[18]提取无人机信号的瞬态上升部分、稳态部分以及瞬态下降部分作为3类图数据,使用集成训练的方法训练多个神经网络模型,并进行综合得到无人机识别结果。文献[19]针对复杂低空信道下的无人机信号开集识别问题,提出了基于差值时频和多质心Open-Max的识别方法,通过提取与信道无关的差值时频特征来降低多径信道干扰,并利用多质心OpenMax优化神经网络结构,有效提高了识别准确率。

需要注意的是,前述基于无线信号的无人机识别方法都依赖一个前提,即信号接收设备只接收单架无人机的信号。然而,实际环境中,多架无人机通常同时存在,造成采集的无线信号混叠多个无人机

信号,给无人机身份识别带来极大挑战^[20-21]。为了实现多无人机强弱信号混叠下的无人机可靠识别,首先需要在混叠信号中检测并分离出单架无人机的信号,此问题又被定义为信号定位问题^[22]。幸运的是,无人机通常具备自动信道选择功能,在工作时会自动选择空闲频段,这使得无人机图传信号可在时频域上被逐一检测并定位^[23-25]。文献[26]基于YOLO框架提出多无人机信号检测与分类方法,利用预锚框^[27]提取信号的时频分布特征^[28],有效区分了Wi-Fi信号与无人机信号。类似地,文献[29]针对脉冲振幅调制(Pulse amplitude modulation,PAM)类调制信号的混叠识别问题,提出“先分离后识别”的方法,为多信号混叠场景下的识别工作提供了参考。

尽管这些方法取得了一定进展,但仍面临诸多挑战。首先,不同型号无人机的图传信号可能具有高度相似的时频参数。以DJI Matrice Pro与DJI Mavic为例,它们的信号带宽均为18.2 MHz,并且数据包持续时间范围重叠严重(如2.07 ms vs. 2 ms),导致传统参数区分方法失效。其次,商用无人机的图传信号普遍采用OFDM调制(如大疆的Lightbridge、OcuSync协议),当同频段存在信号带宽和持续时间相近的OFDM干扰信号时,将进一步加剧混淆风险。并且,实际场景下信号接收设备与不同无人机的距离差异会导致混叠信号信噪比动态变化,而现有方法未深入分析其对信号检测与识别性能的影响。最后,当多架同型号无人机使用相同图传协议进行信号传输时,将造成模型的特征提取难题。为了解决上述问题,本文设计了面向多无人机强弱信号混叠下的信号检测-分离-识别框架。该框架采用YOLO模型作为检测器与分类器,以有效利用信号在时频图上体现出的参数特征进行信号的检测与分类。针对同类别下多无人机的识别,设计了一个融合高效多尺度注意力(Efficient multi-scale attention, EMA)机制^[30]的ResNet识别器,以增强模型的特征提取能力;同时采用优化的Bagging集成方法进行训练,以增强模型的泛化能力,提高同类别无人机的识别精度。本文主要创新点如下:

(1)针对强弱信号混叠下的多无人机识别难题,提出了一种检测-分离-识别方案。首先使用时频分析方法得到接收信号的时频图,在此基础上,利用YOLO检测器在时频图上检测、定位并分离潜在无人机信号,分离后的信号提供了更加精细的时频表达,增强了模型对信号时频特征的学习能力。

(2)针对时频图分辨率有限导致YOLO模型信号定位精度差的问题,提出了一种用于信号分离阶段的数据增强方法。基于信号定位统计误差在识别阶段的训练数据中引入随机偏差,增强模型对分离偏差的鲁棒性,提升泛化能力。

(3)针对同型号无人机个体间识别难题,设计了一个融合EMA注意力机制的ResNet识别器,通过设置注意力机制的通道权重提高模型的特征提取能力,同时提出了一种优化的Bagging集成学习方法,显著提高了识别精度。

(4)基于真实无人机数据集的实验表明,本文所提方案在检测性能与识别性能上均优于已有方案,且具有较好的鲁棒性和较高的识别率。

1 系统模型与问题分析

无人机图传信号大多工作在工业、科学和医疗(Industrial, scientific, medical band, ISM)频段,同频段还有常见的Wi-Fi和蓝牙等信号。这些信号均采用OFDM调制方式,在时频图上具有相似特征,因此给无人机信号的检测与识别带来干扰。考虑 K_u 架无人机与 K_e 个OFDM信号发送设备共存的场景,其中存在 K_{su} 个同型号的不同无人机个体($K_{su} \leq K_u$),则信号检测设备接收到的信号总数为 $K_u + K_e = K$ 。由于不同辐射源的距离与发射信号强度各不相同,接收到的混叠信号具有不同的信噪比。为不失一般性,第 k 架无人机的发射信号可以表示为^[20]

$$x_k(t) = a_k(x_k^I(t) + jx_k^Q(t)) \cdot e^{j2\pi f_{c,k}^e t} \quad (1)$$

式中: $x_k^I(t)$ 和 $x_k^Q(t)$ 分别为经过成型滤波后的I、Q支路基带信号; a_k 为发送的第 k 个信号的幅度; $e^{j2\pi f_{c,k}^e t}$

为频率为 $f_{c,k}^e$ 的复载波信号,用于将无人机信号发射到对应频段上。与之对应地,接收端在相应频段内采样得到的基带信号为

$$r[n] = \sum_1^K b_k x_k[n] \cdot e^{-j2\pi f_{c,k}^e \frac{n}{f_s}} + w[n] \quad (2)$$

式中: $w[n]$ 为环境中的加性高斯白噪声(Additive white Gaussian noise, AWGN), b_k 为接收到的第 k 个信号的幅度, f_c^r 和 f_s 分别表示检测设备的中心频率和采样频率。最终通过短时傅里叶变换得到信号的时频矩阵为

$$R(m,n) = |\text{STFT}\{r[t]\}| = \left| \sum_{\tau=kT}^{kT+L-1} r[\tau] \cdot g[\tau - kT] \cdot e^{-j\frac{2\pi m \tau}{M}} \right| \quad (3)$$

式中: $R(m,n)$ 为时频矩阵里的元素,STFT{}为短时傅里叶变换, m 和 n 分别对应时频矩阵的频率轴索引和时间轴索引, $g[\tau - kT]$ 为窗函数,用于在时间维度上将信号分割成多个近似平稳的小段。

图1展示了接收信号样本的时频图图例,其中共有5个信号($K_u=4$, $K_e=1$)。值得注意的是,DJI M100型号的无人机存在两个不同的个体,其图传信号具有相同的参数特征,而OFDM干扰信号与DJI Matrice的信号参数高度相似。参数重叠现象使得仅依靠带宽和持续时间等传统特征难以实现信号的精准识别,多无人机信号混叠进一步加大了识别难度。并且,现有方法未充分考虑混叠下各个信号的信噪比动态变化对识别性能的影响。

2 混叠信号下的联合检测-分离-识别方案

本文提出的多无人机混叠信号的检测-分离-识别联合方案包含信号检测、信号分离以及信号识别3个步骤,方案整体框架如图2所示。

2.1 信号检测

YOLO是计算机视觉领域用于目标检测的最先进算法之一,可以同时预测所有潜在目标的位置信息与分类结果。对于宽带信号检测来说,YOLO保证了对时频图上所有信号目标的实时检测。

YOLO使用有监督训练来学习如何在一张图像上定位并分类目标。在训练阶段,YOLO的标签包含了5类信息,包

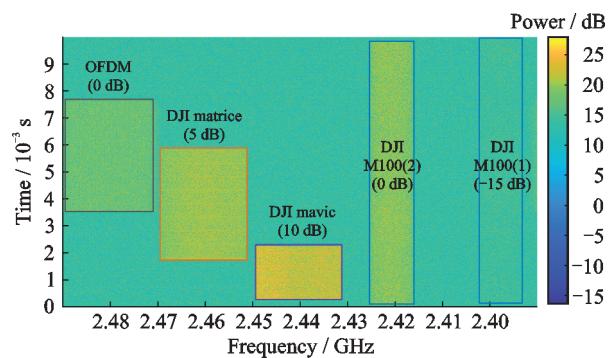


图1 2.4 GHz ISM频带出现的多个不同信噪比信号

Fig.1 Presence of multiple signals with different SNRs at 2.4 GHz ISM band

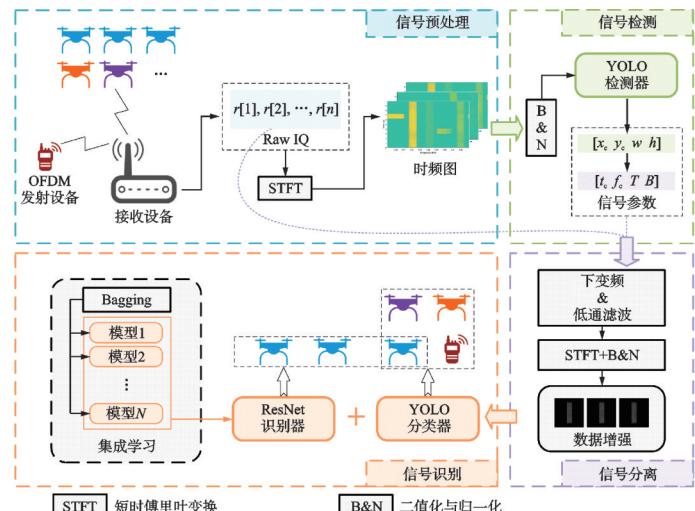


图2 所提方案的总体框架

Fig.2 Overview framework of the proposed scheme

括目标类别、水平中心点、垂直中心点、宽度和高度。图3展示了YOLO在时频图上的信号检测操作。首先, YOLO会将输入图像切割成 $S \times S$ 的网格, 每个网格单元会同步进行目标检测任务, 以确定是否有目标中心点落在单元内。接着, YOLO会在每个单元上生成 B 个预测框, 以涵盖不同大小的目标。为了量化预测框匹配目标的性能, YOLO定义了一个置信度指标 C , 用于指示模型对框中是否存在目标的确定程度, 以及对目标大小的匹配程度。前者表示为目标概率 $\text{Pr}(\text{Object})$, 后者表示为交并比(Intersection-over-union, IoU), 置信度即为 $C = \text{Pr}(\text{Object}) \cdot \text{IoU}$ 。对于分类任务, 每个包含目标的网格单元都会输出一个 N 分类概率。在本文的信号检测阶段, N 被设置为1来区分信号目标和背景噪声。最后, 每个网格单元都会生成1个置信度指标、4个目标定位信息以及1个 N 分类概率, 共同形成一个 $S \times S \times (5B + N)$ 的张量用以表示整个输入图像的预测结果。

假设检测设备采样到的信号为 $r[t]$, 其经过式(3)中的STFT处理后的时频矩阵为 $R(m, n)$, 对应一个大小为 $M \times N$ 的时频图。YOLO检测器会输出时频图上所有潜在信号的归一化中心坐标 $\left(\frac{x_c}{N}, \frac{y_c}{M}\right)$ 、宽度 $\frac{w}{N}$ 以及高度 $\frac{h}{M}$, 它们分别对应着信号的中心时间与中心频率、信号持续时间以及信号带宽。

2.2 信号分离

YOLO检测器输出的各个信号在时频图上的定位信息将被用于信号分离操作, 以提取单个目标信号。信号分离是指从混合信号中提取出各个独立信号的过程, 分离出的单一个体信号作为最基本的时间表达, 具有更加均衡的数据分布特征, 有利于提高后续信号识别的准确率。

信号在时频图上的定位信息包含中心坐标 (x_c, y_c) 、宽度 w 以及高度 h , YOLO检测器输出了这些定位信息按照时频图的尺寸被归一化后的结果。根据时频图的长宽数据和采样频率、采样时间数据, 可以将定位信息转化为信号分离所需的中心频率、持续时间和带宽信息。图4展示了信号分离的过程。信号接收设备首先在接收频段上检测多个潜在目标信号, 在定位目标信号后, 依照定位信息进行下变频操作来补偿目标信号与接收设备中频间的载波频率偏移(Carrier frequency offset, CFO), 最后设置滤波器滤除目标信号带宽外的其他信号与噪声。以下是信号分离的详细步骤。

(1) 参数转换: YOLO检测器的输出结果包含目标信号在时频图上归一化后的中心坐标

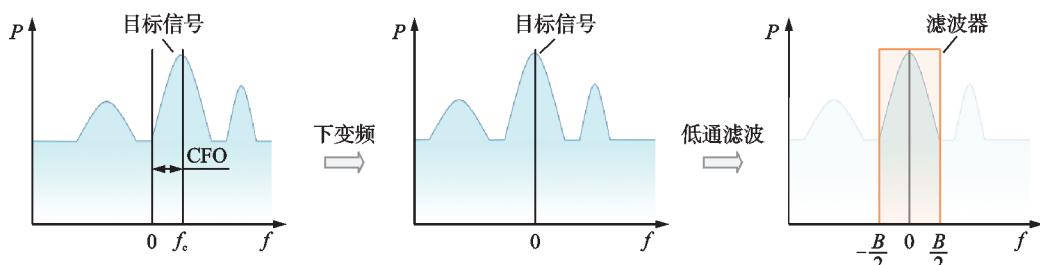


图4 单信号分离过程示意图

Fig.4 Schematic diagram of single signal separation process

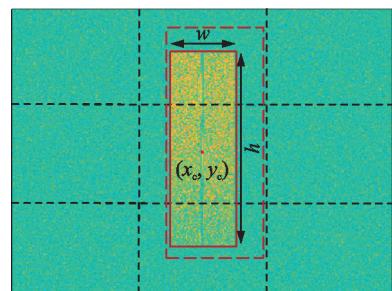


图3 YOLO检测的一个UAV图传信号

Fig.3 YOLO detection of an UAV video signal

$(\frac{x_c}{N}, \frac{y_c}{M})$ 、宽度 $\frac{w}{N}$ 以及高度 $\frac{h}{M}$ 。显然,目标信号的开始时间 \hat{t}_{start} 、结束时间 \hat{t}_{end} 、上频点 \hat{f}_{high} 、下频点 \hat{f}_{low} ,以及中心频率和带宽可由下列公式计算得到

$$\left\{ \begin{array}{l} \hat{t}_{\text{start}} = T_{\text{sig}} \cdot \left(\frac{x_c}{N} - \frac{w}{2N} \right) \\ \hat{t}_{\text{end}} = T_{\text{sig}} \cdot \left(\frac{x_c}{N} + \frac{w}{2N} \right) \\ \hat{f}_{\text{low}} = f_s \cdot \left(\frac{y_c}{M} - \frac{h}{2M} \right) \\ \hat{f}_{\text{high}} = f_s \cdot \left(\frac{y_c}{M} + \frac{h}{2M} \right) \\ \hat{f}_c = f_s \cdot \frac{y_c}{M} \\ B = f_s \cdot \frac{h}{M} \end{array} \right. \quad (4)$$

式中: T_{sig} 为采样信号 $r[t]$ 的采样长度, f_s 为采样频率。

(2) 下变频:采样信号 $r[t]$ 中包含的目标信号可能与接收设备的中频存在 CFO,如图 4 所示。为了消除 CFO,需要对信号进行下变频处理,即

$$r'[t] = r[t] \cdot e^{-j2\pi\hat{f}_c t} \quad (5)$$

式中: $e^{-j2\pi\hat{f}_c t}$ 为中心频率 \hat{f}_c 的复载波,用于将目标信号所在频点搬移到检测设备中频上,以进行后续低通滤波处理。

(3) 低通滤波:将目标信号搬移到设备中频后, $r'[t]$ 中仍存在目标信号频段外的其他信号和噪声,如图 4 所示。为了消除无关信号,需要进行低通滤波,即

$$r''[t] = \text{LPF}_B \{ r'[t] \} \quad (6)$$

式中 $\text{LPF}_B \{\cdot\}$ 代表一个通带为 $[-\frac{B}{2}, \frac{B}{2}]$ 的低通滤波器。最后,在时域进行信号分割,利用检测到的信号起始时间 \hat{t}_{start} 和停止时间 \hat{t}_{end} ,从 $r''[t]$ 中分离出单一个体的目标信号

$$r_k[t] = r''[\hat{t}_{\text{start}} : \hat{t}_{\text{end}}] \quad (7)$$

式中 $r_k[t]$ 即为分离出的第 k 个个体的采样信号,其中包含了单一信号的基带 I/Q 序列。

信号分离依赖于 YOLO 检测器对时频图上各个目标信号的定位信息。式(4)表明定位信息与信号参数存在一一映射关系,然而受限于时频图的分辨率,由定位信息映射得到的信号参数天然存在偏差。式(3)中的时频变换说明了偏差的来源,其中 M 是快速傅里叶变换(Fast Fourier transform,FFT)点数, L 是截断窗长,通常 $M = L$ 。由此可得时频图的频率轴分辨率为 $\frac{f_s}{M}$,即时频图一行包含了 $\frac{f_s}{M}$ 个信号频率采样点。时频图的时间轴分辨率为窗长 L ,即时频图一列包含了 L 个信号时间采样点。当检测器在时频图上的定位信息出现一个像素点的偏移时,映射得到的信号参数就会出现 $\frac{f_s}{M}$ 个频率点或是 L 个时间点的偏差。由于 YOLO 检测器本身对于输入图像的缩放处理步骤,实际偏差可能会更加明显。这样的偏差可能会导致 CFO 效应^[20],降低分类器的性能。为了解决这一问题,本文提出了基于随机偏差的数据增强方法。通过对 YOLO 检测器输出的各个定位参数主动引入随机偏差,得到基于不同随机偏差的信号参数分离出的多个信号数据副本。这些数据副本被用来扩充分类器的训练集,以弥补信号定位偏差造成的训练数据的分布差异,使得模型能够提取不受信号偏差干扰的正确特征。随机偏差定义为

$$\Delta_{\text{para}, i} \in \left[-\frac{c_{\text{para}}}{N}, \frac{c_{\text{para}}}{N} \right] \cup \left[-\frac{c_{\text{para}}}{M}, \frac{c_{\text{para}}}{M} \right] \quad (8)$$

式中: N 和 M 分别为时频图的时间点数与频率点数, $\frac{c_{\text{para}}}{N}$ 为时间定位参数在时间轴上的偏离程度, $\frac{c_{\text{para}}}{M}$ 为频率定位参数在频率轴上的偏离程度, c_{para} 为定位参数的偏离量,由信号检测阶段统计到的参数偏差决定。 $\Delta_{\text{para}, i}$ 将直接作为偏置加在各个定位参数上,其中下标“ i ”代表信号的第 i 个数据副本。

2.3 信号识别

本文串联了一个YOLO分类器与一个ResNet识别器,用于应对复杂的无人机图传信号识别场景。在分离出单一个体信号后,将单一信号的时频图作为YOLO分类器与ResNet识别器的输入。

YOLO分类器用于将各型号无人机图传信号与其他OFDM信号分类,其分类流程与基本原理如2.1节所述,与之不同的是,YOLO模型设置的 N 分类概率中的 N 取值不再为1,而是设置为所需分类的数目,以进行分类任务。二次标注是为了充分利用信号在时频图上体现出的持续时间与带宽信息,有助于YOLO提取这些信息。由于分离后信号只占据了采样频带的中心频段,本文首先将 $M \times N$ 的时频图中心裁剪成 $I \times I$ 的大小,以去除无效信息。在此基础上,将YOLO检测器输出的归一化中心坐标 $\left(\frac{x_c}{N}, \frac{y_c}{M}\right)$ 、宽度 $\frac{w}{N}$ 以及高度 $\frac{h}{M}$ 分别转换为 $\left(\frac{1}{2}, \frac{1}{2}\right), \frac{w}{I}$ 以及 $\frac{h}{I}$,作为YOLO分类器的定位标签。通过二次标注,可以避免神经网络中Resize操作造成的信号细节丢失,进而提高识别精度。

在面对同型号无人机的识别任务时,由于它们图传信号的参数一致,YOLO学习时频图上参数特征的优势将消失;加上YOLO模型本身的性能限制,带来了较低的识别精度。为了提高同型号无人机的识别精度,本文使用了特征提取能力更强的ResNet50模型,进一步融合了EMA注意力机制,并引入Bagging集成学习方法来增强模型对数据的泛化性。ResNet50是一种深度卷积神经网络,属于残差网络(Residual network),通过引入残差块(Residual block)来解决深层神经网络中的梯度消失问题。图5(a)展示了ResNet50的基本残差单元Bottleneck,图中修正线性单元(Rectified linear unit, ReLU)表示为ReLU,包括以下3个卷积层:1×1卷积层用于减少维度,3×3卷积层用于特征提取,1×1卷积层用于恢复维度。这种设计使得ResNet50能够在保持高效特征提取能力的同时,减少计算复杂度和参数数量,从而提高模型的训练和推理效率。如图5(b)所示,ResNet50由50层深度组成,这使得ResNet50能够捕捉到更多的图像特征,提高识别精度。为了进一步提高模型对关键特征的提取能力,本文修改了ResNet的C₄层输出通道,添加EMA^[30]注意力模块自动计算各个通道的权重,以引导模型关注重要特征。EMA注意力机制通过通道分组与跨空间交互增强特征表示。具体而言,EMA首先在特征图的1D与2D维度上,分别利用并行1×1和3×3卷积分支提取局部与全局语义信息,通过矩阵点积操作动态聚合两个维度的输出特征,生成空间注意力权重,以强化模型对关键特征的响应。

作为集成学习方法^[31]的一种,Bagging(Bootstrap aggregating)通过组合多个基学习器来提高模型的泛化能力和稳定性。Bagging的基本思想是通过对训练数据进行有放回的随机抽样,生成多个不同的子数据集,并在这些子数据集上训练多个基学习器,最终通过投票或平均的方式得到最终的预测结果。如图6所示,Bagging方法首先对训练集 D_{train} 中的样本进行有放回采样,生成与 D_{train} 样本数目相同的子数据集 D_i 。Bagging方法基于每个 D_i 训练一个模型 i ,最终平

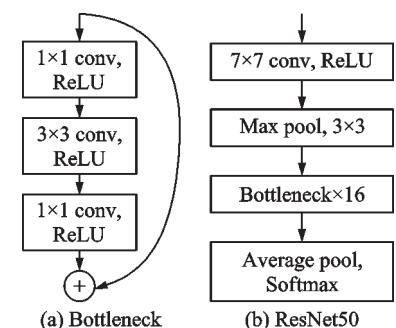


图5 ResNet50的组成块

Fig.5 Building blocks of ResNet50

均每个模型的输出,得到最终的预测结果。通过对多个子模型的预测结果进行平均或投票,Bagging能够有效减少单个模型的过拟合现象,提高模型的稳定性和鲁棒性。本文进一步加入了“半数最优”策略以优化 Bagging 方法,通过筛选验证集上表现最佳的半数子模型,降低由于子数据集分布不均造成的子模型拟合失常风险,得到泛化能力更强的子模型集合,进一步提高识别性能。

3 实验验证

为了验证本文提出的多无人机信号检测与识别方案的性能,本文基于公开数据集进行了仿真实验(<https://github.com/That-Wang/Mul-UAV-Signal-DecRec>)。

3.1 参数设置

(1) 数据集构建。现有的无人机信号公开数据集基本都在单无人机场景下采集,为了模拟多无人机强弱信号混叠场景,需要将采集得到的多个单无人机信号通过信号处理手段进行混叠。而这些公开数据集在进行数据采集时大多覆盖了整个无人机频段,直接相加多个采集到的单无人机信号会带来背景噪声叠加以及工作信道冲突等问题,所以需要先行提取出较为纯净的单个无人机信号,再进行后续的信号混叠。本文基于文献[26]的不同型号无人机图传信号的数据集^[32]、文献[33]的相同型号无人机图传信号数据集、以及 Matlab 仿生成的 OFDM 干扰信号构建了实验所需的多无人机强弱信号混叠的数据集,各无人机图传信号参数如表 1 所示。其中,DJI M100 型号无人机共有 5 架,加上其他 4 种型号无人机发射的图传信号以及 OFDM 干扰信号,总共包含 10 个不同信号。

表 1 无人机图传信号参数

Table 1 UAV video transmission signal parameters

无人机型号	协议/调制方式	持续时间/ms	带宽/MHz
DJI M100	Lightbridge	3.25~9.76	9.6
DJI inspire2	Lightbridge2	9.76	9.6
DJI mini2	Ocusync2	1.07	18.2
DJI matrice pro	Lightbridge2	2.07~5.11	18.2
DJI mavic	Ocusync2	1~5	18.2
OFDM 干扰(仿真)	QPSK/16 QAM	1~9.76	9.6/18.2

为了充分验证强弱信号混叠对检测与识别性能的影响,本文设置了不同的测试场景:场景 A 与场景 B。在两个场景下采集的每个混叠信号由 5 个不同信号混叠生成,这些信号来自于 1 个 OFDM 干扰源和 9 架无人机(包含 5 架同型号无人机),其信噪比均在 -15~10 dB 范围内。不同的是,场景 A 下混叠信号中的 4 个信号的信噪比分别固定为 -5 dB、0 dB、5 dB 和 10 dB,剩余 1 个信号信噪比在 -15~10 dB 范围内随机变化,以控制混叠的强弱信号变量,考察方案对信噪比变化的鲁棒性。场景 B 下混叠信号中的各个信号信噪比随机变化,模拟实际多无人机飞行环境,考察方案的总体性能。场景 A 共采集了 1 680 个混叠信号样本作为测试集(由 8 400 个信号混叠生成,其中 1 680 个信号的信噪比随机变化);场景 B 共采集了 1 680 个混叠信号样本(由 8 400 个信号混叠生成),按照 6:2:2 的比例被划分为训练集、验证集和测试集。

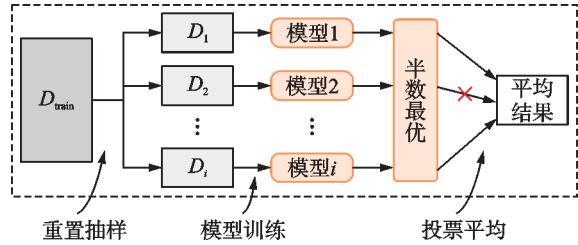


图 6 优化的 Bagging 集成学习方法
Fig.6 Optimized Bagging ensemble learning method

(2) 实验参数设置。本文通过 Matlab 完成数据的仿真与预处理操作, 相关信号处理参数如表 2 所示。本文所使用的 YOLOv5m 模型以及 ResNet 50 模型依靠 Python 中的 Pytorch 工具库搭建, 模型的训练与测试在一个 CPU 为 Intel 酷睿 i5-13400, GPU 为 NVIDIA GeForce RTX 4060Ti 的计算机平台上进行。YOLOv5m 模型使用了原作者的初始设置^[34], 其在检测阶段的样本批量大小为 4, 在识别阶段的样本批量大小为 16, 对应这两个阶段中单个时频图上的信号数目差异。基于 Bagging 的 ResNet 50 模型的子模型数量为 20, 样本批量大小为 16, 每个子模型均使用 Adam 作为优化器, 学习率设置为 0.000 5, 权重衰减设置为 0.000 05, 并加入了失活率为 0.5 的随机失活层(Dropout layer)来防止过拟合。

3.2 无人机检测与识别性能分析

对于检测任务来说, IoU 指标是评估目标检测模型性能的重要标准, 它通过计算预测区域与真实区域的重叠程度来评估检测的准确性。IoU 的计算公式为

$$\text{IoU} = \frac{A_1}{A_U} \quad (9)$$

式中: A_1 代表预测区域和真实区域的重叠面积(即两个区域的交集), A_U 代表预测区域和真实区域的总面积(即两个区域的并集)。IoU 的值在 0~1 之间, 1 表示完美重叠。在目标检测任务中, IoU 的阈值通常被设置为 0.5, 用于判断预测是否为正确检测(True positive, TP)。高于阈值的预测被认为是正确的, 低于阈值的则被视为错误检测(False positive, FP)。实验中, IoU 根据时频图上信号区域所占的像素点数量计算, 信号的确检记为 TP, 信号的误检(噪声检测为信号)记为 FP, 信号的漏检记为 FN。在此基础上, $F_{1\text{-score}}$ 指标适用于评估方案在检测与识别任务中的综合性能。 $F_{1\text{-score}}$ 是精确率(Precision)和召回率(Recall)的调和平均数, 它们的计算公式分别为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (10)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (11)$$

$$F_{1\text{-score}} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (12)$$

式中: 精确率表示在所有被预测为正类的样本中, 实际为正类的比例, 它反映了模型预测的准确性; 召回率表示在所有实际为正类的样本中, 被正确预测为正类的比例, 它反映了模型对正类样本的识别能力。精确率高意味着低误检率, 而召回率高意味着低漏检率。 $F_{1\text{-score}}$ 的值介于 0 到 1 之间, 其中 1 表示完美的精确率和召回率, 它在精确率和召回率之间提供了一个平衡, 用于权衡模型的综合性能。

为了验证所提方案的检测性能, 本文选取了 One-stage 方案下的 YOLOv5m 模型, 文献[26]用提出的 YOLO-Lite 模型与一个常用于图像分割的 Unet 模型进行对比实验。图 7 展示了这 4 种模型的检测性能。在场景 A 下, 所提方案使用的 YOLO 检测器基本检测出了所有信号, 各个信噪比下的平均 $F_{1\text{-score}}$ 达到了 0.997, 优于其他模型。One-stage 方案下的 YOLO 模型不仅要关注信号与噪声之间的区别, 也要关注不同信号之间的区别, 带来了些微性能下降。YOLO-Lite 模型检测性能不佳, 一方面是因为它的

表 2 信号处理参数

Table 2 Signal processing parameters

参数	值
STFT 窗长 L	2 048
信号分离前时频图大小 $M \times N$	2048×488
信号分离后时频图大小 $I \times I$	512×512
信号采样时间 T_{sig}/ms	10
信号采样频率 f_s/MHz	100
信噪比范围/dB	-15:5:10

轻量化设计限制了性能上限,另一方面是因为本文复杂的强弱信号混叠场景降低了它的特征提取能力,使其难以区分弱信号与背景噪声,从而带来了较多的误检与漏检。Unet模型主要由卷积层和池化层组成,尽管可以进行像素级检测,但受限于有限的卷积核感受野,导致其缺乏对全局信息的捕捉能力,造成了较多的误检漏检数量。随着信噪比的增加,YOLO-Lite模型和Unet模型反而出现了性能下降,这说明在强弱信号混叠的影响下,信号在时频图上的分布特征彼此干扰,高信噪比信号对时频图分布特征的干扰更为明显,造成了它们的性能损失。

为了验证所提方案的识别性能,本文选取了One-stage方案下的YOLOv5m模型,文献[26]用提出的YOLO-Lite模型与一个ResNet50模型进行对比实验,其中One-stage方案下YOLO模型的检测性能与对比中的YOLO模型相同。根据统计结果,设置式(8)中时间轴上的 $c_{\text{para}} = 0.01 \times L \approx 20$,频率轴上的 $c_{\text{para}} = 0.001 \times L \approx 2$,用于对识别阶段的训练集进行数据增强。ResNet模型同样应用了数据增强以保证公平性,而不涉及信号分离的YOLO(One-stage)模型和YOLO-Lite模型没有应用数据增强。为验证所提方案对信噪比动态变化的鲁棒性,在场景A下测试了各方法的 $F_{1\text{-score}}$ 。图8展示了针对不同型号无人机的识别性能,所提方案在各个信噪比下均取得了更高的 $F_{1\text{-score}}$ 。ResNet模型和YOLO(One-stage)模型的性能表现稍差。YOLO-Lite模型则具有最差的性能表现。在-15 dB的低信噪比条件下,所提方案的 $F_{1\text{-score}}$ 达到了0.949,优于YOLO(One-stage)模型的0.919和ResNet模型的0.808,YOLO-Lite模型则基本无法正确分类低信噪比信号。此时不使用数据增强的方案出现了11.7%的性能下降,证明了所提数据增强方法能够弥补信号分离中参数偏差带来的负面影响,提升模型在低信噪比场景下的分类效果。当信噪比提升至-10 dB时,所提方案的 $F_{1\text{-score}}$ 上涨至0.995并保持良好性能,YOLO(One-stage)模型的 $F_{1\text{-score}}$ 则稳定在0.989附近,并在-5 dB时出现小幅性能下降,表明其易受强弱信号混叠干扰。YOLO-Lite模型的 $F_{1\text{-score}}$ 呈现出了上凸函数的特点,表明其难以适应强弱信号混叠场景。

图9展示了针对同型号无人机的识别性能,在场景A的各个信噪比下,所提方案的 $F_{1\text{-score}}$ 始终领先。随着信噪比的增加,所提方案具有明显的性能上涨趋势,而其余方法都出现了一定程度的趋势放缓或

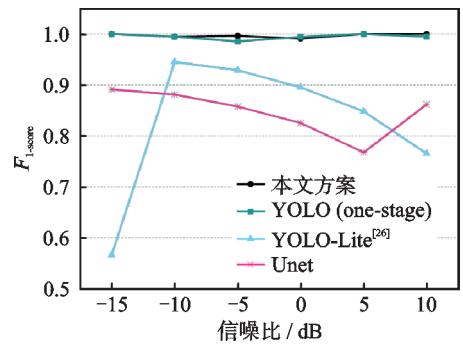


图7 场景A中无人机信号检测性能

Fig.7 Detection performance of UAV signals under Scenario A

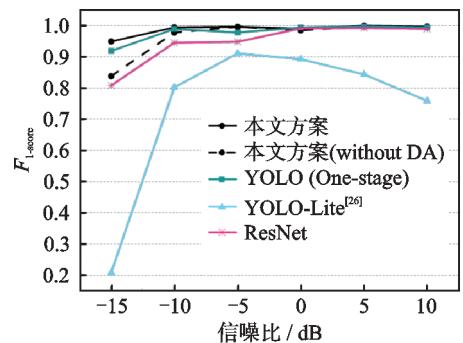


图8 场景A中不同型号无人机信号识别性能

Fig.8 Recognition performance of heterogeneous UAV signals under Scenario A

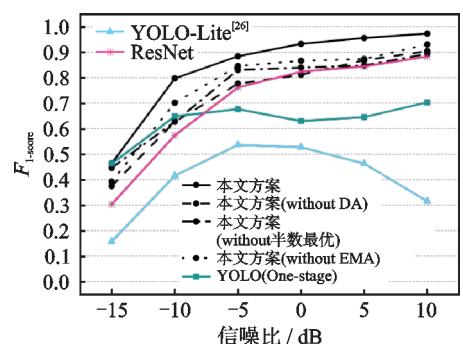


图9 场景A中同型号无人机信号识别性能

Fig.9 Recognition performance of homogeneous UAV signals under Scenario A

是性能回撤,证明了方案在强弱信号混叠影响下的鲁棒性优势。移除优化的Bagging方法和EMA后,方案的平均性能分别下降了10.25%和7.19%,这是失去了优化的Bagging方法的模型泛化增益和EMA的关键特征提取能力导致的。在-15 dB的低信噪比条件下,所提方案的 $F_{1\text{-score}}$ 达到了0.464,优于YOLO(One-stage)模型的0.463和ResNet模型的0.304,而YOLO-Lite模型基本无法正确识别低信噪比信号。当信噪比提升至-10 dB时,所提方案的 $F_{1\text{-score}}$ 上涨至0.798且随着信噪比增加持续增长,而YOLO(One-stage)模型的 $F_{1\text{-score}}$ 稳定在0.649附近,甚至在0 dB时出现小幅性能下降,表明其易受强弱信号混叠干扰。YOLO-Lite模型的 $F_{1\text{-score}}$ 依旧呈现出了上凸函数的特点,进一步表明传统One-stage模型在强弱信号混叠场景下适应能力较差,而所提方案通过信号分离-数据增强-信号识别流程有效解决了这一问题。除此以外,方案在没有经过数据增强时出现了10.78%的平均性能下降,进一步证明了所提数据增强方法的有效性。

为了进一步验证所提方案在干扰信号和同型号无人机共存环境下的识别性能,基于场景B进行了无人机分类与识别实验,结果如图10所示。可以看出,对于不同型号和同型号无人机间的分类与识别,所提方案都取得了最低的混淆数目。在无人机类间分类上,所提方案较YOLO(One-stage)模型和ResNet模型分别降低了55.6%和75%的混淆数目。在抗干扰能力上,尽管所有方法均在OFDM干扰信号上出现误判,所提方案凭借YOLO分类器对时频图上信号特征的充分利用,将混淆数目相较于YOLO(One-stage)模型降低了42.11%。在同型号无人机识别上,所提方案获得了84.29%的平均识别率,相较于YOLO(One-stage)模型的62.74%、YOLO-Lite模型的30.83%以及ResNet模型的75.12%,存在明显性能优势。

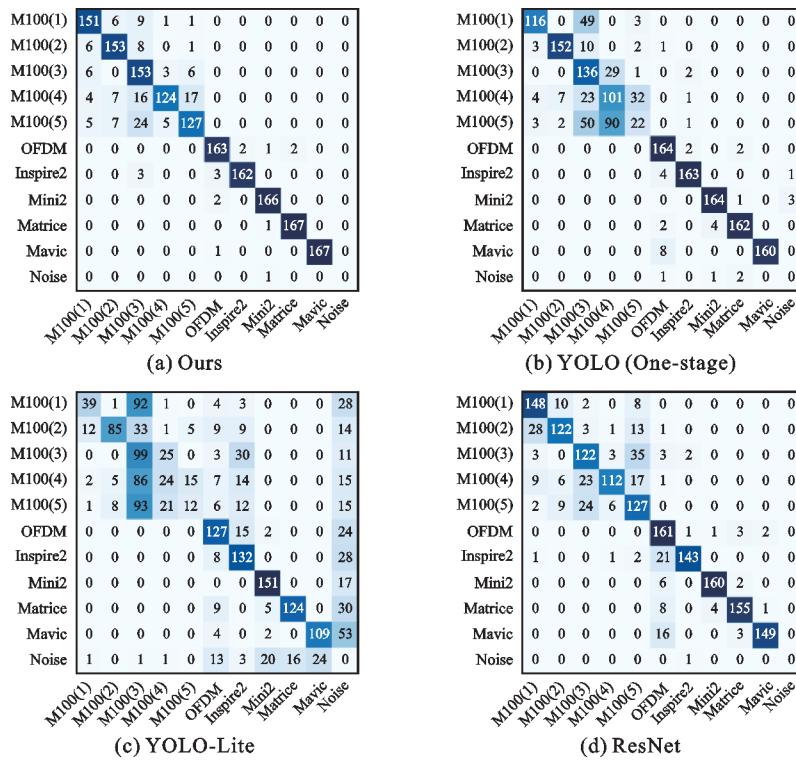


图10 场景B中无人机信号分类与识别混淆矩阵

Fig.10 Confusion matrix of classification and recognition of UAV signals under Scenario B

4 结束语

针对多无人机信号混叠场景下因信噪比动态变化、干扰信号混淆及同型号无人机共存导致的识别难题,本文提出了多无人机混叠信号下的联合检测-分离-识别方案。该方案通过YOLO检测器在时频图上精准定位混叠信号,并利用数据增强方法有效解决了分离偏差对识别性能的影响。在此基础上,进一步优化YOLO分类器对信号带宽与持续时间的特征提取能力,提高了对不同型号无人机的分类性能;同时加入EMA注意力机制并引入优化的Bagging集成学习方法,有效提高了对同型号无人机的识别性能。

参考文献:

- [1] 中华人民共和国中央人民政府. 2024年政府工作报告[R]. 北京: 中华人民共和国中央人民政府, 2024.
The Central People's Government of the People's Republic of China. Report on the work of the government 2024[R]. Beijing: The Central People's Government of the People's Republic of China, 2024.
- [2] 蒋文全, 高豪云, 郑佳秋, 等. 无人机在民用行业应用研究综述[J]. 机电工程技术, 2024, 54(9): 119-124, 183.
JIANG Wenquan, GAO Haoyun, ZHENG Jiaqiu, et al. Review of researches on the application of drones in the civilian industry[J]. Mechanical & Electrical Engineering Technology, 2024, 54(9): 119-124, 183.
- [3] 杨鹏, 梁雨欣, 孔雨新, 等. 面向高效巡检任务推理的边缘辅助无人机机载视频压缩与传输[J]. 物联网学报, 2024, 8(4): 129-139.
YANG Peng, LIANG Yuxin, KONG Yuxin, et al. Edge-assisted UAV onboard video compression and transmission for efficient inference of patrolling tasks[J]. Chinese Journal on Internet of Things, 2024, 8(4): 129-139.
- [4] 李玉涛, 刘双振. 公安视域下民用无人机"黑飞"执法困境与对策研究[J]. 铁道警察学院学报, 2023, 33(5): 44-48.
- [5] 余丁辰, 王威, 王加琪, 等. 基于收缩自编码器的无人机GPS欺骗攻击协同检测方法[J]. 信号处理, 2024, 40(4): 706-718.
SHE Dingchen, WANG Wei, WANG Jiaqi, et al. Collaborative detection method of UAV GPS spoofing attack based on shrink autoencoder[J]. Journal of Signal Processing, 2024, 40(4): 706-718.
- [6] PAN Hengchang, WANG Yuanshuo, WANG Wei, et al. Privacy-preserving location authentication for low-altitude UAVs: A blockchain-based approach[J]. Security and Safety, 2024, 3: 2024004.
- [7] HUIZING A, HEILIGERS M, DEKKER B, et al. Deep learning for classification of mini-UAVs using micro-Doppler spectrograms in cognitive radar[J]. IEEE Aerospace and Electronic Systems Magazine, 2019, 34(11): 46-56.
- [8] OJDANIĆ D, SINN A, NAVERSCHNIGG C, et al. Feasibility analysis of optical UAV detection over long distances using robotic telescopes[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(5): 5148-5157.
- [9] SHI Zhiguo, CHANG Xianyu, YANG Chaoqun, et al. An acoustic-based surveillance system for amateur drones detection and localization[J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 2731-2739.
- [10] XIAO Yue, ZHANG Xuejun. Micro-UAV detection and identification based on radio frequency signature[C]//Proceedings of the 2019 6th International Conference on Systems and Informatics (ICSAI). Shanghai, China: IEEE, 2019: 1056-1062.
- [11] ESMAEILI H, KERMANI A. Radio frequency fingerprint identification of drones based on variational mode decomposition [C]//Proceedings of the 2022 8th Iranian Conference on Signal Processing and Intelligent Systems (ICSPI). Behshahr, The Islamic Republic of Iran: IEEE, 2022: 1-5.
- [12] XU Chengtao, CHEN Bowen, LIU Yongxin, et al. RF fingerprint measurement for detecting multiple amateur drones based on STFT and feature reduction[C]//Proceedings of the 2020 Integrated Communications Navigation and Surveillance Conference (ICNS). Herndon, USA: IEEE, 2020: 1-7.
- [13] EZUMA M, ERDEN F, KUMAR ANJINAPPA C, et al. Detection and classification of UAVs using RF fingerprints in the presence of Wi-Fi and bluetooth interference[J]. IEEE Open Journal of the Communications Society, 2019, 1: 60-76.
- [14] 那振宇, 程留洋, 孙鸿晨, 等. 基于深度学习的无人机检测和识别研究综述[J]. 信号处理, 2024, 40(4): 609-624.
NA Zhenyu, CHENG Liuyang, SUN Hongchen, et al. Survey on UAV detection and identification based on deep learning[J]. Journal of Signal Processing, 2024, 40(4): 609-624.
- [15] ZUO Ming, XIE Shuguo, ZHANG Xian, et al. Recognition of UAV video signal using RF fingerprints in the presence of WiFi interference[J]. IEEE Access, 2021, 9: 88844-88851.

- [16] BREMNES K, MOEN R, YEDURI S R, et al. Classification of UAVs utilizing fixed boundary empirical wavelet sub-bands of RF fingerprints and deep convolutional neural network[J]. *IEEE Sensors Journal*, 2022, 22(21): 21248-21256.
- [17] ZHANG Hanshuo, LI Tao, SU Nan, et al. Drone identification based on normalized cyclic prefix correlation spectrum[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2024, 10(4): 1241-1252.
- [18] KANG J, SHIN Y, LEE H, et al. Radio frequency fingerprinting for frequency hopping emitter identification[J]. *Applied Sciences*, 2021, 11(22): 10812.
- [19] 杨宁, 胡景明, 张邦宁, 等. 低空智联网中基于多质心OpenMax的无人机开集识别方法[J]. 数据采集与处理, 2024, 39(1): 60-70.
YANG Ning, HU Jingming, ZHANG Bangning, et al. Open set identification method for unmanned aerial vehicles based on multi-center OpenMax in low-altitude intelligent network[J]. *Journal of Data Acquisition and Processing*, 2024, 39(1): 60-70.
- [20] LI Tao, XUE Chaozheng, LI Yongzhao, et al. Augmentation based on spectrogram segments for UAV operating channel-robust CNN classifiers[C]//Proceedings of the 2024 IEEE 99th Vehicular Technology Conference (VTC2024-Spring). Singapore, Singapore: IEEE, 2024: 1-6.
- [21] ZHANG Hanshuo, LI Tao, LI Yongzhao, et al. RF-based drone classification under complex electromagnetic environments using deep learning[J]. *IEEE Sensors Journal*, 2023, 23(6): 6099-6108.
- [22] WEST N, ROY T, O'SHEA T. Wideband signal localization with spectral segmentation[EB/OL]. (2021-10-01)[2025-04-01]. <https://arxiv.org/abs/2110.00583v1>.
- [23] SCHEERS B, TEGUIG D, LE NIR V. Wideband spectrum sensing technique based on Goodness-of-Fit testing[C]// Proceedings of the 2015 International Conference on Military Communications and Information Systems (ICMCIS). Cracow, Poland: IEEE, 2015: 1-6.
- [24] LIN Meiyang, ZHANG Xiaoxu, TIAN Ye, et al. Multi-signal detection framework: A deep learning based carrier frequency and bandwidth estimation[J]. *Sensors*, 2022, 22(10): 3909.
- [25] DENG Zhe, LEI Jing. Spectrogram-based frequency hopping signal detection in a complex electromagnetic environment[C]// Proceedings of the 2022 7th International Conference on Signal and Image Processing (ICSIP). Suzhou, China: IEEE, 2022: 6-10.
- [26] BASAK S, RAJENDRAN S, POLLIN S, et al. Combined RF-based drone detection and classification[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2022, 8(1): 111-120.
- [27] LI Weihao, WANG Keren, YOU Ling, et al. A new deep learning framework for HF signal detection in wideband spectrogram [J]. *IEEE Signal Processing Letters*, 2022, 29:1342-1346.
- [28] VAGOLLARI A, SCHRAM V, WICKE W, et al. Joint detection and classification of RF signals using deep learning[C]// Proceedings of 2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring). Helsinki, Finland: IEEE, 2021: 1-7.
- [29] VAGOLLARI A, HIRSCHBECK M, GERSTACKER W. An end-to-end deep learning framework for wideband signal recognition[J]. *IEEE Access*, 2023, 11: 52899-52922.
- [30] OUYANG Daliang, HE Su, ZHANG Guozhong, et al. Efficient multi-scale attention module with cross-spatial learning[C]// Proceedings of the 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece: IEEE, 2023: 1-5.
- [31] SHE Dingchen, WANG Wei, YIN Zhisheng, et al. GPS spoofing attack recognition for UAVs with limited samples[J]. *IEEE Internet of Things Journal*, 2025, 12(1): 250-261.
- [32] BASAK S, POLLIN S, SCHEERS B, et al. Drone RF dataset[EB/OL]. (2025-04-01). <https://doi:10.48804/HZRVNZ>.
- [33] SOLTANI N, REUS-MUNS G, SALEHI B, et al. RF fingerprinting unmanned aerial vehicles with non-standard transmitter waveforms[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(12): 15518-15531.
- [34] JOCHER G. YOLOv5 7.0[EB/OL]. [2024-03-12]. <https://github.com/ultralytics/yolov5>.

作者简介:



王加琪(2001-),男,硕士研究生,研究方向:低空无人机监管技术,E-mail:nu-aawjq@nuaa.edu.cn。



王威(1990-),通信作者,男,研究员,研究方向:无线通信、空天地一体化网络、低空智联网,E-mail:wei_wang@nuaa.edu.cn。