

一种基于微多普勒和机器学习的无人机目标分类识别技术

邢政^{1,2,3}, 周良将^{1,2,4}, 董书航^{1,2,3}, 温智磊^{1,2,4}

(1. 中国科学院空天信息创新研究院, 北京 100190; 2. 微波成像技术国家级重点实验室, 北京 100190;
3. 中国科学院大学电子电气与通信工程学院, 北京 100049; 4. 齐鲁空天信息研究院, 山东济南 250132)

摘要: 近年来,随着科技发展,无人机行业高速发展,空域的情况变得愈加复杂,消费级无人机的入侵事件日益增多,对无人机防控系统的需求越来越迫切。飞鸟和无人机都是典型的“低慢小”目标,二者的回波特征、运动模式都有极其相似之处,如何对二者进行有效的观测、区分和追踪已成为保障空中航路安全研究中的重要问题。本文针对传统方法难以将二者区分的问题,首先利用仿真建立无人机和飞鸟的数学及物理模型,并对二者的微动特征进行提取,利用卷积神经网络和集成学习方法对其进行区分,在此基础上对实测数据进行识别,证明了本文方法的有效性。

关键词: 微多普勒; 机器学习; 目标识别; 卷积网络; 集成学习

中图分类号: TN957.51

文献标志码: A

文章编号: 1672-2337(2024)05-0549-08

引用格式: 邢政,周良将,董书航,等.一种基于微多普勒和机器学习的无人机目标分类识别技术[J].雷达科学与技术,2024,22(5):549-556.

BING Zheng, ZHOU Liangjiang, DONG Shuhang, et al. A Classification and Recognition Method for UAV Targets Based on Micro-Doppler and Machine Learning[J]. Radar Science and Technology, 2024, 22(5):549-556.

A Classification and Recognition Method for UAV Targets Based on Micro-Doppler and Machine Learning

BING Zheng^{1,2,3}, ZHOU Liangjiang^{1,2,4}, DONG Shuhang^{1,2,3}, WEN Zhilei^{1,2,4}

(1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100190, China;
2. National Key Laboratory of Microwave Imaging Technology, Beijing 100190, China;
3. School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China;
4. Qilu Aerospace Information Research Institute, Chinese Academy of Sciences, Jinan 250132, China)

Abstract: The drone has been a key threat as its infiltration events are incredibly increasing, due to the rapid development of the drone industry, which makes it a critical demand to develop drone prevention systems. Birds and drones are both classic objects that have low attitude, slow speed and small scale, leading to similar echo characteristics and movement patterns. To ensure the safety of airlines, it has been an important issue to observe, separate and track them two. To solve the problem, firstly, the mathematical and physical model of the drone and the bird are established by simulation, and the micro-motion characteristics of both are extracted. Then, the two kinds of objects are distinguished using convolutional neural network and ensemble learning methods. Based on which, the real field data are processed, and the result has proved the validity of the method.

Key words: micro-Doppler; machine learning; object recognition; convolutional neural network; ensemble learning

0 引言

无人机于20世纪20年代诞生,最早被应用于战争领域^[1]。近年来,随着科技进步,无人机不断

向机体小型化、成本低廉化、操作简便化的方向快速发展,因而在军事和民用领域都得到了广泛的应用^[2]。然而,无人机技术进步的同时也导致了无人机使用门槛的大幅下降,因而带来了一系列公

共安全领域乃至国家安全领域的监管问题,例如,国内机场多次出现的“黑飞”无人机扰航事件^[3],民用无人机在空中相撞,以及无人机本身的伤人事件等。为应对这种情况,一方面要在法律层面上加大对无人机的监管,另一方面也要加快研究无人机的反制技术。其中,旋翼无人机的飞行高度低、飞行速度低、雷达反射面积小,是典型的“低空慢速小目标”,而这些特征与在空中飞行的鸟类十分类似,因此对空中目标进行检测和分类是无人机反制的前提和关键环节^[4]。

无人机和飞鸟所处空中环境杂波十分复杂,且低慢小目标自身的回波也有多样化的趋势,传统方法在上述背景下难以实现有效的高性能检测。随着雷达技术的高速发展,获取目标的微动特征成为可能。由于飞鸟和无人机都存在微动特征,因此通过分析其微多普勒特征可将不同目标分离,实现目标的探测和识别。尽管微动特征能够为目标的识别和分类提供许多有效信息,但微动特征没有可以简单提取的模式特点,因此存在特征提取难、特征识别难的问题,需要研究出智能化的方法来解决这一问题。分离多分量微多普勒信号的方法主要有两类,基于信号分解的方法和基于时频分析^[5]的方法。近年来快速发展的机器学习的方法是一种智能化的处理方法,这为微动特征的提取和分类提供了良好基础。

然而,目前对机器学习方法的结构、参数以及样本数据集的研究还比较缺乏,针对这一问题,本文提出了一种基于卷积神经网络深度学习和集成学习方法的空中目标检测与分类方法,通过对无人机和飞鸟的运动特征进行建模,并利用机器学习对雷达回波的时频特性进行分析,从而实现处在杂波中无人机和飞鸟目标的识别和分类,并最终利用仿真和实测数据分别从理论上和实际应用中验证了方法的有效性。

1 微动目标模型及干扰杂波模型描述

1.1 无人机模型描述

常见的无人机布局为“X型”,对角线上的旋翼旋转方向相同,相邻旋翼旋转方向相反。且在前进和后退时,分别有两对旋翼同时保持在前进方

向和后退方向上^[6],调节旋翼的转速即可操控无人机进行悬停或移动,如图1所示。



图1 一种四旋翼无人机

无人机旋翼分力与机体的横滚角 ϕ 、俯仰角 θ 和偏航角 ψ 所具有的关系为

$$\begin{bmatrix} f_x \\ f_y \\ f_z \end{bmatrix} = f \begin{bmatrix} \cos \phi \sin \theta \cos \psi + \sin \phi \sin \psi \\ \cos \phi \sin \theta \sin \psi - \sin \phi \cos \psi \\ \cos \phi \cos \theta \end{bmatrix} \quad (1)$$

从而可根据旋翼的转速得到无人机任意时刻的加速度 a ,进而得到无人机任意时刻的速度和位置。设置一仿真雷达,其与无人机的位置关系如图2所示,其发出调频连续波,则综上可得无人机旋翼总的回波信号为^[7]

$$\begin{aligned} s_{\Sigma}(t) = \sum_{k=0}^{N-1} s_{L_k}(t) = L \exp \left\{ -j \frac{4\pi}{\lambda} \left[R_0 + z_0 \sin \beta \right] \right\} \cdot \\ \sum_{k=0}^{N-1} \sin c \left\{ \frac{4\pi}{\lambda} \frac{L}{2} \cos \beta \cos \Omega t + \varphi_0 + \frac{k2\pi}{N} \right\} \cdot \\ \exp \left\{ -j \Phi_k(t) \right\} \end{aligned} \quad (2)$$

式中, z_0 为旋翼叶片的高度, L 为叶片的整个长度, N 为叶片的个数。




图2 雷达与无人机的空间位置关系

1.2 飞鸟模型描述

飞鸟的身体结构大致可分为两部分:主体和翅膀。其中,飞鸟翅膀的运动,是鸟类飞行过程中微动特征的主要表现形式,因此翅膀的运动模式是研究的重点。翅膀主要由肱骨,尺骨和桡骨,以及腕骨、指骨和掌骨这三部分构成,并可以用翼展和半翼展来衡量翅膀的宏观尺寸特征,如图3所示。



图3 鸟类翅膀的主要构成

翅膀的运动形式主要有三种,分别为扑翼、扭翼和扫翼。在扑翼运动中,以 f_{nap} 为振翅频率,扑翼角度 ψ 随时间 t 的变化定义为

$$\psi(t) = A_{\psi} \sin(2\pi f_{\text{nap}} t) \quad (3)$$

以 r 为半翼展,则翼尖的坐标位置为

$$P_{\text{nap}}(t) = \begin{bmatrix} 0 \\ r \cdot \cos \psi(t) \\ r \cdot \sin \psi(t) \end{bmatrix} \quad (4)$$

若运动过程中还存在扭翼和扫翼运动,则可通过扑翼矩阵、扭翼矩阵和扫翼矩阵的关系推导出翼尖的最终位置。

1.3 干扰杂波模型描述

1.3.1 环境杂波

为了模拟现实环境中的情况,本课题还研究了实际环境中常见的气象杂波、复杂地形的杂波,以及海杂波。仿真时,根据不同建模分别生成了服从不同分布的环境杂波,并使用不同的频谱对其进行描述。其中,概率分布的建模如下:

1) Rayleigh分布

以 x 表示杂波回波的包络振幅,以 σ^2 表示它的

功率,则 x 的概率密度函数为

$$f(x) = \frac{x}{\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (5)$$

2) LogNormal分布

以 x 代表杂波回波的包络分布, σ 代表 $\ln x$ 的标准差, x_m 代表 x 的中值,则 x 的概率密度函数为

$$f(x) = \frac{1}{\sqrt{2\pi} \sigma x} \exp\left[-\frac{\ln^2(x/x_m)}{2\sigma^2}\right] \quad (6)$$

3) Weibull分布

以 x 代表杂波回波的包络振幅, x_m 代表 x 的中值, α 为斜度参数,则 x 的概率密度函数为

$$f(x) = \frac{\alpha x^{\alpha-1}}{x_m^\alpha} \exp[-(x/x_m)^\alpha] \quad (7)$$

仿真中,使用的干扰频谱描述如下:

1) Gaussian谱模型

$$S(f) = \exp\left(-\frac{f^2}{2\sigma_f^2}\right) \quad (8)$$

式中, σ_f 为杂波谱的标准差。

2) Cauchy谱模型

$$S(f) = \frac{1}{1 + \left(\frac{f}{f_c}\right)^2} \quad (9)$$

式中, f_c 为截止频率。

1.3.2 无关目标的运动杂波

在雷达探测的实际环境中,除飞鸟和旋翼无人机等相关目标外,还存在其他的移动目标。这些移动目标亦会产生许多运动杂波,对目标识别造成影响,因此有必要对无关目标的杂波进行建模。

轮式车辆是常见的地面干扰之一,其车身体和车轮的回波信号可描述为^[8]

$$s_i(t) = \rho \exp[j2\pi f_c(t - \tau)] + \sum_{i=1}^k \rho_i \exp[j2\pi f_c(t - \tau_i)] \quad (10)$$

式中, ρ 为车辆主体的散射系数, ρ_i 为车轮上不同散射点的散射系数, τ 为车辆主体的回波延时, τ_i 为车轮上不同散射点的回波延时。

直升机是另一种常见的空中干扰源,其螺旋桨的回波信号描述与无人机类似^[9-10],但由于直升机螺旋桨的转速和尺寸都与无人机有较大区别,因此可对二者进行区分。

2 识别算法描述

2.1 神经网络概述

神经网络是深度学习的基础,是机器学习中一种重要的方法。最早的神经网络是MP模型,即参考生物神经元的结构而提出的神经元模型。其中,卷积神经网络已在图像识别、自然语言处理等领域得到了越来越广泛的应用,常见的卷积神经网络模型有 AlexNet^[11], LeNet^[12], ResNet^[13]等。此外,集成学习具有较好的抗噪声能力,且训练速度快,对数据集无归一化要求,因此也得到了较好的发展。目前,机器学习在雷达信号处理领域也有越来越多的应用^[14]。

2.2 特征挖掘

本文的分类识别算法基于目标的微动特征进行,因而首先应对目标回波进行时频分析。利用短时傅里叶变换对仿真无人机和鸟类的回波进行分析,如图4和图5所示。本文从以下几个方面对二者的时频分析进行特征提取:

1) 计量一段时间内回波多普勒频率极大值 $P_{\max i}$ 和极小值 $P_{\min i}$, 并计算其绝对值的平均值,即

$$P_{\max} = \frac{|P_{\max 1}| + |P_{\max 2}| + \cdots + |P_{\max n}|}{n} \quad (11)$$

$$P_{\min} = \frac{|P_{\min 1}| + |P_{\min 2}| + \cdots + |P_{\min n}|}{n} \quad (12)$$

通常情况下,无人机旋翼旋转频率远大于鸟类振翅频率,因此二者微多普勒频率的绝对值会有较大的差异。

2) 检验回波的时频图中的突变特征。无人机在空中进行运动状态切换时,旋翼的转速会发生突然的较大改变,且改变后的转速可能持续较长时间;而鸟类无法在空中悬停,当其停止振翅时,只能进行时间较短的滑行,无法长期保持,因此二者回波的多普勒频率突变情况会有所不同。

3) 统计回波时频图的能量特征,通过不同部分回波的能量 E_i 计算回波总能量 E , 即 $E = \sum E_i$ 。无人机的旋翼通常由高强度的碳纤维和塑料制成,而鸟类的翅膀由羽毛、骨骼和血液构成,二者的 RCS 相差较大,导致回波强度不同。




图4 仿真得到无人机飞行回波信号的时频特征




图5 仿真得到鸟类飞行回波信号的时频特征

2.3 神经网络构建

2.3.1 适用于学习隐性特征的卷积神经网络构建

样本回波的时频特性中,除前文提到的3种数据特征外,还可能包含其他难以手动归类总结的隐性特征,如果不能有效利用回波的隐性特征,会使算法识别能力有所欠缺。此外,由于回波数据可能来自各种不同场景和型号下的雷达设备,不同样本中可能包含不尽相同的系统误差和噪声、干扰等;根据使用雷达规格的不同,回波强度和采样率也可能不完全相同。这一方面会造成识别性能的下降,另一方面也对识别算法在不同数据集上的通用性提出了要求。利用网络学习大量不同数据的隐性特征,可以有效提升算法的泛化能力,使其能够适应各种不同的数据样本。因此本文首先利用机器学习对此部分隐性特征进行量化,学习隐性特征的信息,从而实现提高识别准确率和泛化能力的目的。为了保证隐性特征不被损失或丢失,本文采取将回波的时频特征作为输入,直接送进网络进行学习的方法。

用于对象分类识别的机器学习方法,其输入通常为较小的图像,常见分辨率为 28×28 至 512×512 不等,即数量级约为 $10^2 \sim 10^5$ 。而本文中回波的时频特征矩阵数量级为 10^6 ,因此已有网络不能完全满足时频特征矩阵的训练要求。由于卷积神经网络中的池化层可以在最大限度保持图像的空间信息特征不丢失的前提下,大幅降低显存的占用,并能够通过减少参数的方法减小计算量,因此在网络输入数据量大的场合具有独特的优势。

本文在构建网络时,充分发挥了卷积网络能

够减少计算量的特点,采用了4层卷积层,使得在GPU上对网络进行训练成为可能。在卷积层之后,构建了一个隐藏全连接层以及一个全连接输出层,从而尽量提升网络的学习能力,且不会占用过多GPU资源,并满足网络对无人机和飞鸟进行隐性特征提取的目的,降低过拟合的风险。激活函数方面,本文使用了Leaky ReLU函数,保证了网络对非线性特征的拟合能力,并允许训练过程中使用反向传播,同时提高计算效率。卷积网络最终结构如图6所示。




图6 本文所使用卷积网络结构

2.3.2 关联集成学习流程

为了更好地处理回波中的噪声,以及应对不同数据集间系统误差差别较大的问题,本文还利用集成学习方法对上节中提取的样本回波时频特性三种显性特征进行学习和训练。由于三种特征的数据量很小,因此采用全连接网络进行学习。将集成学习后生成的三组参数与上述卷积神经网络学习的输出参数进行组合,并进一步利用全连接网络模型来进行训练和分类,以达到最终提高识别准确率的目的。集成学习方法方面,本文采用了Adaboost方法,这是由于不同来源的样本其特征的置信度不同,因此通过Adaboost方法使其自动调整不同特征间的权重,从而实现较好的分类识别效果。算法的流程图如图7所示。




图7 算法流程图

3 实验验证

3.1 实验数据集构建及数据预处理

3.1.1 实验数据集构建

目前已有的方法实验大多利用理想仿真数据进行。尽管为了还原真实情况,在数据中加入了噪声和干扰,但大多加入的是高斯噪声,未能贴近实际。本文根据前文中对噪声的研究,分别向仿真数据中添加了不同种类的环境杂波。

除仿真数据之外,本文还利用外场实验数据构建了真实的飞鸟和无人机数据集,其中无人机数据包含DJI mini四旋翼无人机和DJI m600六旋翼无人机的回波数据,飞鸟数据包含仿真飞鸟无人机回波数据。飞鸟无人机利用仿生学原理,基于鸟类振翅飞行的原理进行飞行,在起飞、空中飞行和降落过程中,其动作特征和形态均与真正的鸟类相似,且在实验过程中可控度高,有效解决了真正的飞鸟回波难以捕捉的问题。其外形如图8所示。



图8 飞鸟无人机

本文共包含了10条大型回波数据,其中每条数据都包含无人机和飞鸟在不同空间位置、不同飞行轨迹和不同飞行速度下的运动回波,涵盖了较多的运动情况,因此数据集具有较高的代表性。

3.1.2 数据预处理

1) 实测数据拆分与提取

本文使用的实测回波数据每条数据时间跨度较大,且包含了目标进行不同运动姿态时的回波,而网络进行一次识别所需时间较短,因此一条回波数据中所含样本点数远超一次识别所需点数,可对数据进行拆分。为使数据具有代表性,本文在拆分时进行了手动筛选,去除了回波起始和结束阶段不含目标的部分,以及部分雷达工作间隙无有效回波的部分,最终获得了实测无人机样本4 000个和飞鸟样本5 000个。

2) 实测数据去噪

为尽可能避免其他环境噪声和杂波对采集雷达回波的干扰,在实验过程中已对实验场地进行了精心选择,但回波中的噪声和干扰依然很强。因此本文首先对实测数据运用了脉冲对消和方位累积的方法去除环境杂波。除环境杂波外,仍有许多无关目标的回波也被采集到,如地面上行驶的车辆等,且无关目标的回波很强,这对目标识别造成了极大干扰。因此在数据去噪过程中,还需要使用目标检测技术,利用目标的运动轨迹、回波强度等特征,对空中关注目标的回波进行提取。有关目标检测的研究已较为成熟^[15-22],因此不作为本文研究的重点。在数据去噪过程中,本文使用CFAR方法进行目标检测^[22-23],检测结果如图9所示。检测图中,方框部分为无人机和飞鸟目标的主要分布位置。根据关注目标的位置信息,利用




图9 目标检测结果

匹配滤波的方法对关注目标的回波进行提取,达到去杂波和干扰的效果,从而获得了环境杂波和其他运动目标杂波均较少的实测数据样本。

3) 样本抽样和插值

通常情况下,不同雷达系统传感器的采样率和数据记录间隔都不尽相同,造成样本点的时间间隔有所不同。而网络训练时,训练样本是基于固定的时间间隔构建,因此要对实测数据进行插值,以对齐时间。由于实测数据的采样率较高,因此插值时利用了线性插值的方法。

4) 时频变换

为了适应学习隐性特征的神经网络训练和测试需求,需要将数据样本进行短时傅里叶变换,并独立构成数据集。

3.2 实验结果分析

为了证明总体识别算法的有效性,本文首先利用仿真数据对算法的检测准确率进行了测试。在取得了较好的结果后,再利用实测数据进行验证,并在实测数据中采用集成学习流程,以提高整体算法的检测准确率。最终实验数据集为上述经过预处理后并进行随机打乱后的仿真和实测数据样本集,其中60%作为训练集,20%作为验证集,20%作为测试集。

3.2.1 评价指标

利用目标检测技术,可将不同距离门内的目标进行分离,因此本文的目标识别仅考虑单目标的情况。检测准确率 ε 的具体定义如下:

$$\varepsilon = \frac{M}{N} \quad (13)$$

式中, M 为检测正确样本数, N 为总样本数。

3.2.2 基于仿真目标的准确率检测实验

利用仿真数据可控的特点,构建仿真数据集时,生成了一系列包含不同信杂比回波的数据样本,并将其利用在网络的训练和测试中。测试样本中共有两种,第一类测试样本仅由环境杂波和目标回波构成,可视为理想测试环境的仿真样本;第二类测试样本除环境杂波和目标回波外,还包含运动车辆、运动直升机等其他无关目标的回波,是干扰较强环境下的仿真样本。考虑到实际情况中,这些无关目标的回波通常无法很好地去除,因

此在第二类测试样本中,无关样本的回波功率保持恒定,信噪比只针对关注的目标回波和环境杂波而言。

在第一次仿真测试中,仅依靠卷积网络学习样本的隐性特征对第一类样本进行识别。通过测试发现,在第一类仿真测试样本的识别准确率检测实验中,卷积网络可取得较好的成果,检测结果如图10所示。从第一次测试结果可以看出,当信噪比不低于6 dB时,目标识别的准确率非常高,能够保持在98%以上,且识别准确率几乎不受信噪比变化的影响。当信噪比低于6 dB且高于-6 dB时,识别准确率随着信噪比的下降而缓慢下降至73%左右。当信噪比进一步下降,识别准确率会快速下降,直至信噪比达到-13 dB时,检测准确率最低,为50%左右,此时目标的微动特征逐渐被杂波掩盖,网络已无法很好地根据输入样本的特征进行目标分类。总体而言,卷积网络在第一类样本上表现出了较好的识别能力,无需再利用时频特征进行进一步检测。





图10 第一类仿真目标在卷积网络下的检测准确率

在第二次仿真测试中,测试目标为第二类样本。若只利用隐性特征对目标进行分类,检测准确率会大幅下降,其检测结果如图11(a)所示。通过与第一次测试对比可知,其他无关目标对卷积网络的检测结果影响较大,即使回波的信噪比很高时,检测正确率也不超过80%,因此需要利用时频特征,进一步对样本进行识别。引入集成学习后,检测准确率如图11(b)、(c)、(d)所示。由检测结果可知,引入时频特征可有效提升检测准确率。当同时利用三种时频特征时,若样本的信噪比较高,识别准确率能够达到89%以上;当信噪比不


低于-3 dB时,仍有68%以上的检测准确率;当信噪比进一步降低至-10 dB时,检测准确率降低到50%,说明回波信噪比过低,超出了算法识别的极限。

3.2.3 基于实测目标的准确率检测实验


如前文所述,实测目标的信噪比较低,因为实测数据中不仅包含大量环境杂波,还包含地面车辆等其他无关目标运动杂波。在检测过程中,首先尝试只利用对消的方法对数据进行去噪,得到




(a) 仅采用隐性特征



(b) 隐性特征+极值检测



(c) 隐性特征+极值检测+突变识别



(d) 隐性特征+极值检测+突变识别+能量识别

图11 第二类仿真目标在卷积网络下的检测准确率

的检测结果非常不理想。因此,在数据预处理过程中,利用目标检测和匹配滤波的方法对回波中其他无关目标的杂波进行去除,是非常有必要的。在进行二次杂波去除后,分次引入不同时频数据特征,得到实测数据的检测准确率如表1所示。

表1 实际目标检测准确率

实际目标分类检测特征	DJI mini 四旋翼无人机	DJI m600 六旋翼无人机	0.8 m 翼展飞鸟无人机	1.0 m 翼展飞鸟无人机
仅采用隐性特征	0.702	0.734	0.650	0.668
隐性特征+极值检测	0.760	0.794	0.741	0.751
隐性特征+极值检测+突变识别	0.763	0.792	0.748	0.759
隐性特征+极值检测+突变识别+能量识别	0.792	0.813	0.774	0.779

由检测结果可知,仅依靠检测隐性特征实现的检测准确率有限,引入极值检测的集成学习参数后,检测准确率实现了较大的提高。然而,当引入突变识别的集成学习参数时,检测能力的提升有限,对大型无人机的识别能力甚至出现了少许下降,这可能是因为本文采用的数据集中并非包含真正的飞鸟,因此其仍会出现较多的姿态突变,影响了检测的准确率。最终进一步利用能量识别的学习参数进行检测后,实现了较高的检测准确率。

4 结束语

针对利用机器学习对低慢小微动信号进行智

能化分析和提取方法中网络构建方法、训练参数和数据集构建较少的问题,本文提出了一种将卷积神经网络和集成学习相结合,对空中无人机与飞鸟的微动特征进行检测与识别的方法。在本方法中,首先利用卷积神经网络对目标雷达回波的隐性特征进行提取,并结合目标微动特征的极值、突变和能量等特点,利用集成学习对目标进行识别和分类,并在实际应用中取得了较好的效果。仿真分析和实测结果均证明该方法的有效性和合理性,具有一定的实用价值。由于目前数据较少,网络的泛化能力还有待进一步提升,对于采样率较低的样本,则需要更加智能和精细的插值方法,这将是本文后续研究工作的一个重要方面。

参考文献:

- [1] 张云秀,曾庆达,张炜.无人机发展综述[J].河南科技,2017(9):58-59.
- [2] 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.
- [3] 于飞,刘东华,贺飞扬.无人机“黑飞”对电磁空间安全的挑战[J].中国无线电,2018(8):43-44.
- [4] 屈旭涛,庄东晔,谢海斌.“低慢小”无人机探测方法[J].指挥控制与仿真,2020,42(2):128-135.
- [5] 宋晨,周良将,吴一戎,等.基于时频集中度指标的多旋翼无人机微动特征参数估计方法[J].电子与信息学报,2020,42(8):2029-2036.
- [6] 王晓亮,王承祥,何伟琨.利用飞控特征的四旋翼无人机雷达回波信号仿真[J].信号处理,2021,37(2):292-303.
- [7] 王承祥.利用飞控特征的多旋翼无人机雷达回波建模[D].天津:中国民航大学,2021.
- [8] 朱凌智.基于微多普勒效应的无人机载雷达对地面目标分类方法研究[D].南京:南京理工大学,2021.
- [9] 张朝伟,夏赛强,杨军,等.低信噪比条件下直升机微动特征提取方法[J].雷达科学与技术,2021,19(6):689-696.
- [10] 秦晓雨,邓彬,董俊,等.太赫兹雷达直升机旋翼目标微动特性研究[J].太赫兹科学与电子信息学报,2023,21(3):317-324.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Image-Net Classification with Deep Convolutional Neural Networks [J]. Advances in Neural Information Processing Systems, 2012, 25(2):84-90.
- [12] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep Residual Learning for Image Recognition [C]// 2016 IEEE Conference on Computer (下转第568页)