基于小波熵特征的无人机射频信号识别算法研究

刘 冰*①② 时明心① 刘佳琪①
①(中国民航大学交通科学与工程学院 天津 300300)
②(天津市城市空中交通系统技术与装备重点实验室 天津 300300)

摘 要：随着无人机技术的迅猛发展及其在多个领域的广泛应用，确保无人机的安全飞行和有效监管成为了一个重要的研究课题。该文提出一种基于小波熵特征和优化神经网络的无人机飞控射频信号分类识别方法，旨在解决复杂电磁环境中无人机信号识别的问题。通过提取射频信号的小波熵特征并构建特征向量，结合由大蔗鼠优化算法(GCRA)优化的支持向量机(SVM)分类器，实现了对不同型号无人机的有效分类。实验使用了公开数据集DroneRFa中的常见无人机射频信号，经过10-折交叉验证测试，该方法对于6种型号的无人机分类准确率达到了97%以上，最高可达99%，证明了所提方法的有效性和可靠性。该研究为无人机自主避障、路径规划以及多机协同作业提供了重要的技术支持。

关键词：小波熵；优化神经网络；无人机射频信号；识别算法
中图分类号：TN98 **文献标识码**：A **文章编号**：1009-5896(2025)08-2736-10
DOI: 10.11999/JEIT250051 **CSTR**: 32379.14.JEIT250051

1 引言

近年来无人机技术的快速发展，无人机已经从军事领域迅速扩展到民用、商业和个人娱乐等多个领域，展现出前所未有的应用潜力。从农业植保、环境监测、物流配送到影视拍摄、应急救援，无人机凭借其灵活高效的特点，正深刻改变着人们的生活和工作方式。无人机的广泛应用带来了诸多便利，但同时也引发了诸如安全、隐私、监管等一系列问题[1–4]。特别是在复杂电磁环境中，如何确保无人机的安全飞行，防止非法干扰与恶意操控，成为了亟待解决的问题。无人机飞控射频信号作为无人机通信的核心手段，精准识别无人机的射频信号，不仅可以有效监控无人机的飞行状态，防止未经授权的飞行活动，还可以为无人机的自主避障、路径规划和多机协同作业提供关键支持[5–7]。

针对无人机的检测与识别，国内外已经有部分学者展开了相关的研究，文献[8]提出一种利用无人机的无线信号进行无人机的监测与跟踪的方法，主要包括主动跟踪和被动监听两种工作模式，并且使用无线开放接入研究平台(Wireless open-Access Research Platform, WARP)和通用软件无线电外设(Universal Software Radio Peripheral, USRP)进行了半实物仿真验证。文献[9]分别提取无人机的回波短时傅里叶变换和倒频谱的多普勒特征，利用多普勒特征进行无人机的分类与识别，研究重心主要在旋翼型无人机的转速、旋翼角速度、旋翼直径等。文献[10]提出了一种基于平移-倾斜-变焦(Pan-Tilt-Zoom, -PTZ)摄像机的系统，用于监控业余无人机。首先，使用光流和方向梯度直方图(Histogram of Oriented Gradients, HOG)方法计算出边界。离线训练深度学习预训练模型残差网络(Residual Network, ResNet,)，以检测计算边界内的无人机，并用大疆幻影2进行了一系测试实验。文献[11]提出了一种基于优化以点为中心的目标检测方法(CenterNet: objects as points, CenterNet)和联合注意力机制的低空无人机检测方法，针对传统算法中小目标漏检率高的问题，引入解耦的非局部算子捕捉图像关联性，并利用无人机群个体相似性降低漏检率。为了获得更精准的检测框，改进了标签编码策略和边界框回归方式，引入定位质量损失函数，提高了检测框的准确性和紧凑度。文献[12]提出一种基于多维信号特征的无人机探测识别方法。通过自适应三角阈值法筛选无人机无线信号，并解析信道状态信息，然后利用正交匹配追踪算法进行参数

收稿日期：2025-01-22；改回日期：2025-04-15；网络出版：2025-04-29
*通信作者： 刘冰 liub@cauc.edu.cn
基金项目：国家自然科学基金青年项目(6240011305)，天津市城市空中交通系统技术与装备重点实验室开放课题基金(TJKL-UAM-202403)，石家庄市垂直起降固定翼无人机智能研究重点实验室开放课题(KF2024-2)，云南省无人自主系统重点实验室开放课题(202501YB02)
Foundation Items: The National Natural Science Foundation of China (6240011305), The Key Laboratory of Technology and Equipment of Tianjin Urban Air Transportation System Open Fund (TJKL-UAM-202403), Shijiazhuang Vertical Take-off and Landing Fixed-wing UAV Intelligence Research Key Laboratory Open Fund (KF2024-2), The Foundation of Yunnan Key Laboratory of Unmanned Autonomous Systems (202501YB02)

估计以定位无人机，最后提取盒维数和径积分双谱特征实现分类识别。

为解决无人机飞控射频信号识别的难题，本文提出一种利用小波熵特征和优化神经网络的无人机飞控射频分类识别方法，通过提取射频信号的小波熵，构建能够表征不同无人机类型的特征向量，利用优化神经网络分类器进行分类识别，提升了对无人机飞行状态的监控能力，为后续无人机自主避障、路径规划等提供了技术基础保障。

2　小波熵特征理论

2.1　小波理论

小波变换能够同时提供时间域和频率域的信息，在应用于随时间变化的信号时具有显著优势。通过改变尺度参数，可以调整时间与频率分辨率之间的权衡，从而允许从粗到细地观察信号特征。与傅里叶变换不同，小波变换提供了良好的时频局部性，这意味着它不仅能够确定信号成分的频率信息，还能精确指出这些成分出现的时间位置。

信息学中熵的概念最初由Shannon[13]提出，也称香浓熵，用来表示信号或系统的混乱程度，香浓熵值越大，信号或系统的混乱程度越高，越不稳定。信号经过小波多尺度分解处理后，可以将各个尺度下的小波系数转换为概率分布序列，基于这一序列所计算出的熵值，被称为小波熵，量化了系数矩阵的稀疏性，并且能够体现整个信号的不确定性和复杂度。

设信号$x(n)$经上述快速变换后，在第j分解尺度下k时刻的高频分量系数为$D_j(k)$，低频分量系数为$A_j(k)$，进行单支重构后得到的信号分量$D_j(k)$，$A_j(k)$所包含信息的频带范围为

$$\begin{cases} D_j(k):[2^{-(j+1)}f_{\mathrm{s}},2^{-j}f_{\mathrm{s}}] \\ A_j(k):[0,2^{-(j+1)}f_{\mathrm{s}}] \end{cases},j=1,2,\cdots,m \tag{1}$$

其中，f_{s}表示信号的采样频率，经过上式的变换之后，原始信号$x(n)$则可以用各个频率分量之和的形式进行表示

$$\begin{aligned} x(n)&=D_1(n)+A_1(n)\\ &=D_1(n)+D_2(n)+A_2(n)\\ &=\sum_{j=1}^{m}D_j(n)+A_m(n) \end{aligned} \tag{2}$$

为统一表示，将$A_m(n)$表示为$D_{j+1}(n)$，则式(2)可表达为

$$x(n)=\sum_{j=1}^{m+1}D_j(n) \tag{3}$$

在进行连续的小波变化时，取不同的离散分解尺度$j=1,2,\cdots,m$，可以通过上式得到一系列的离散小波系数D_j，分解得到的D_j并不是信号$x(n)$的完备表示，多尺度的离散小波变换可以在一定程度反应原始信号的时频分布[14]。

2.2　小波能谱熵

对于原始信号$x(n)$进行尺度为m的小波变换可以得到$x(n)=\sum_{j=1}^{m+1}D_j(n)$，$j=1,2,\cdots,m$，对小波信号进行离散傅里叶变换，即对式(3)进行离散傅里叶变换后可以得到

$$X(k)=\sum_{n=1}^{N}d_i(n)W_N^{kn} \tag{4}$$

其中，$d_i(n)$为原始信号$x(n)$小波分解后的高频分量，$W_N^{kn}=\mathrm{e}^{-\mathrm{j}\frac{2\pi}{N}kn}$。$m$尺度的小波分解后，每个尺度的小波能量谱可以通过$X(k)$的表达式进一步计算得到，假设$E=E_1,E_2,\cdots,E_m$为信号$x(n)$在$m$个尺度上的小波能量谱，则$E$可以表示为

$$E_k=\frac{1}{N}|X(k)|^2,k=1,2,\cdots,j+1 \tag{5}$$

分别求取小波分解后m个尺度上小波能量谱占据总能量的比值

$$p_k=\frac{E_k}{X(k)}=\frac{1}{N}\sum_{n=1}^{N}d_i(n)W_N^{kn} \tag{6}$$

根据香浓熵相关理论，结合上式可以得到原始信号的小波能谱熵可以表示为

$$H=-\sum_{k=1}^{N}p_k\times\log_2 p_k \tag{7}$$

3　数据预处理

3.1　无人机飞控射频信号数据集

由于无人机飞控射频信号涉及相关技术装备要求较高，目前少有在无人机型号数量、有效频段数量等均满足研究要求的数据集，部分研究人员[15–17]利用自己非开源的数据集进行相关技术的验证，这并不能对于不同的方法有统一的评价标准。文献[18]的研究团队公开了相关的数据集(DroneRFa)，该数据集中包含了目前国内市面上较常见的共计24类无人机的飞控射频信号，并且射频信号的采集覆盖了3个开放频段(Industrial Scientific Medical, ISM)，包括915 MHz, 2.4 GHz和5.8 GHz。如图1所示。

3.2　射频信号数据预处理

DroneRFa公开数据集中的数据，受限于设备读写性能，数据采集使用了“采-存-采-存”的模式，设置的采样周期为10兆个数据点，为保证数据

(a) DJI Phantom 3 (b) DJI AVATA (c) DJI MATRICE 200

(d) DJI Air 2S (e) DJI Mini 3 Pro (f) DJI Inspire 2

图 1 DroneRFa数据集公开的部分无人机型号

的连续性，数据预处理过程中，截取每个数据集50 000个采样点的数据，这样既能够兼顾处理数据的实时性，又能保证包含特征的显著性。DroneRFa数据集覆盖了3个开放频段：915 MHz, 2.4 GHz和5.8 GHz，这些都是无人机常用的控制和通信频段。数据集包含了24种常见的无人机飞控射频信号，部分示例型号包括DJI Phantom 3, DJI AVATA, DJI MATRICE 200等。数据集中的数据包括4通道数据，通道名为“RF0_I”，“RF0_Q”，“RF1_I”和“RF1_Q”，其中“RF0”通道数据来自射频接收机的第1通道，“RF1”通道数据来自射频接收机的第2通道，“I”为基带信号的同相(In-phase)分量值，“Q”为基带信号的正交(Quadrature)分量值。

3层小波变换提供了一个适中的分解层次，既能捕捉到信号中的高频细节成分，也能保留低频的概貌信息。随着小波变换层数的增加，计算量也会相应增大。3层小波变换能够在保证足够特征提取精度的同时，保持较低的计算成本。图2所示为选取的DJ Phantom 3无人机飞控射频信号分别在RF0_I通道、RF0_Q通道、RF1_I通道和RF1_Q通道信号分别进行3层小波变换后的时域波形图，其中，cd1表示1层高频系数，cd2表示2层高频系数，cd3表示3层高频系数，ca3表示3层低频系数。

4 无人机飞控射频信号分类识别算法

4.1 特征矩阵构建

每种型号的无人机飞控射频信号共计包含4个通道的数据，分别选取“RF0_I”，“RF0_Q”，“RF1_I”和“RF1_Q”进行3层小波变换，变换过程利用MATLAB 2020b中的小波函数箱Wavelet Toolbox，选取Daubechies小波中的“db4”进行小波分解。然后按照第2节的方法进行小波熵特征提取，每一个通道的数据可以产生一个小波熵特征，因此可以构成一个4维度的特征矩阵，特征矩阵构造过程如图3所示。图3中的4个通道数据均选取50 000个样本点进行小波变换，以保证数据处理的高效性。

为验证本节所提的4维小波熵特征的有效性，利用F检验[19]对6种类型无人机射频信号构成的特征矩阵进行差异显著性分析，给定显著性水平$\alpha=0.05$，原假设为H_0：检验的总体方差相等，来自于同一总体。备择假设为H_1：检验的样本来自于不同样本。

每一型号的无人机飞控射频数据选取1 000个样本，经过小波熵特征矩阵的构造之后，对不同型号相同维度之间的差异显著性进行检验，共计生成4个不同维度的检验结果。表1所示为利用F检验的返回p值。由表1可知，每个特征维度F检验的返回p值均远远小于显著性水平$\alpha=0.05$，因此可以得出拒绝原假设，接受备择假设的结论，即4个通道RF0_I, RF0_Q, RF1_I和RF1_Q的小波熵特征，在不同的无人机型号之间，均具有差异显著性，可以作为分类识别的特征依据。

4.2 优化支持向量机搭建

选取大蔗鼠优化算法(Greater Cane Rat Algorithm, GCRA)进行支持向量机(Support Vector

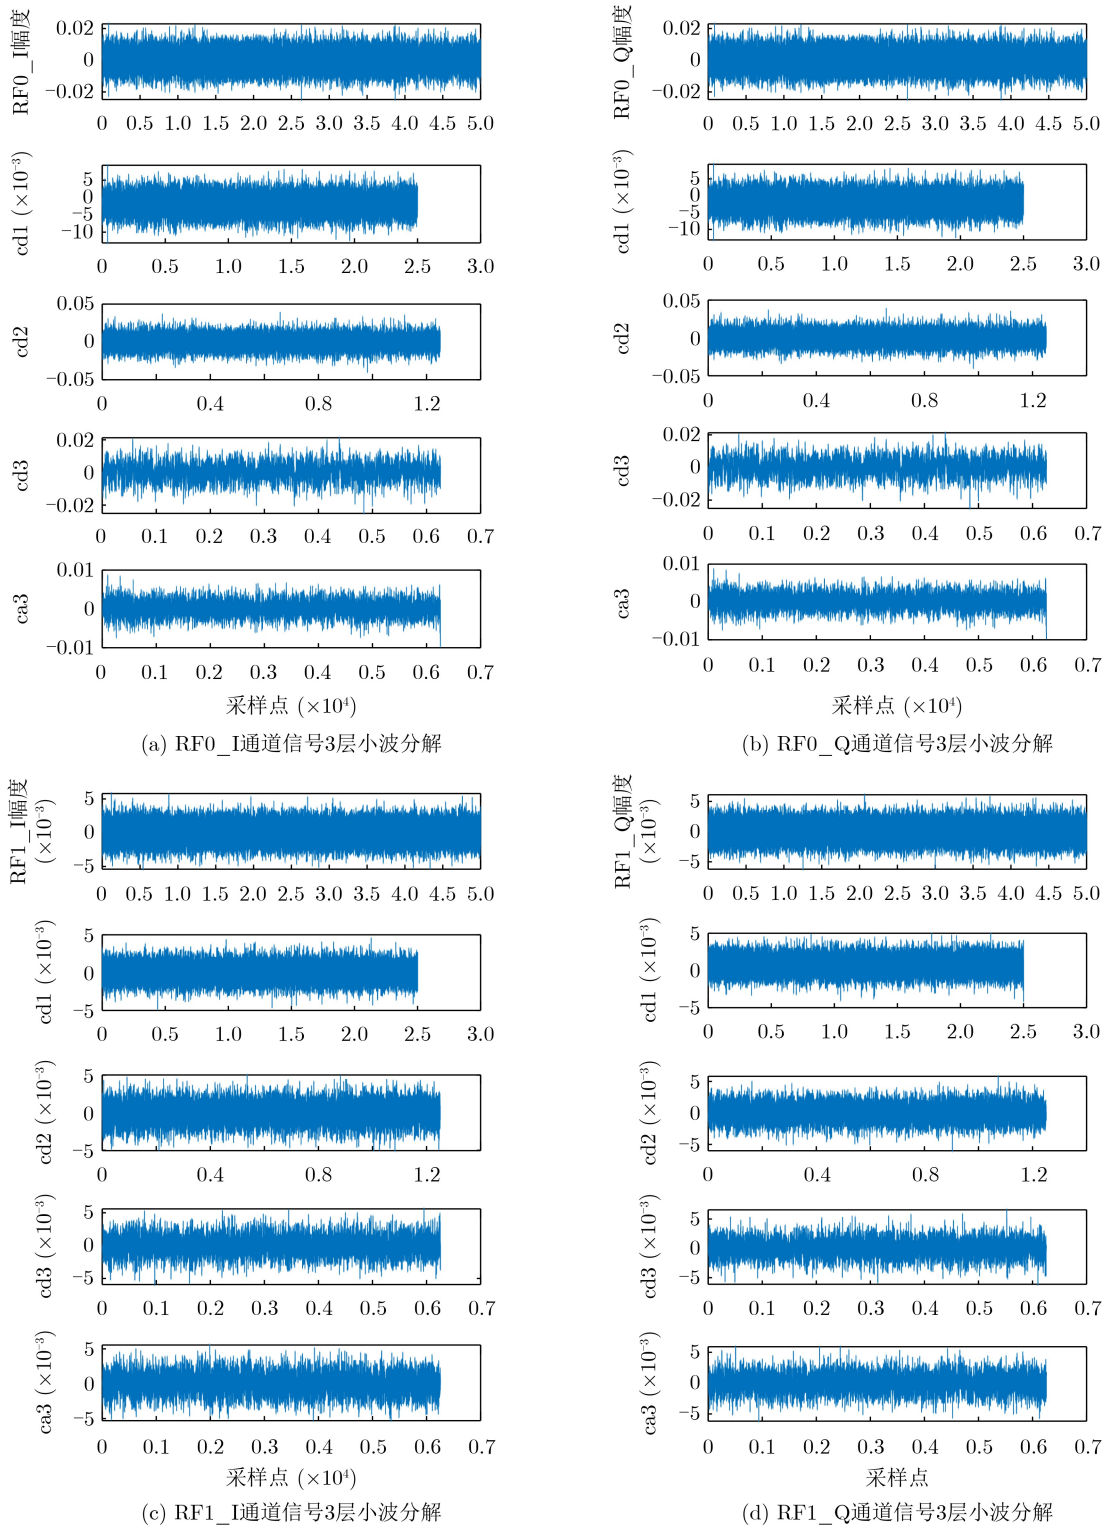

(a) RF0_I通道信号3层小波分解　(b) RF0_Q通道信号3层小波分解

(c) RF1_I通道信号3层小波分解　(d) RF1_Q通道信号3层小波分解

图 2 无人机飞控射频信号4通道小波分解

Machine, SVM)的参数优化器。GCRA是受蔗鼠觅食行为启发而提出的一种新的元启发式算法[20]。GCRA主要包括以下几个步骤：

初始化：在第j维随机生成第i个位置的个体大鼠$x_{i,j}$

$$x_{i,j} = \text{rand} \times (\text{UB}_j - \text{LB}_j) + \text{LB}_j \tag{8}$$

其中，rand表示0和1之间的随机数，UB表示上边界，LB表示下边界。

探索阶段。在它们的领地周围建造它们的庇护所。它们离开不同的庇护所去觅食，要么沿着小路找到以前的食物来源，要么寻找新的食物来源并留下痕迹，该过程可表示为

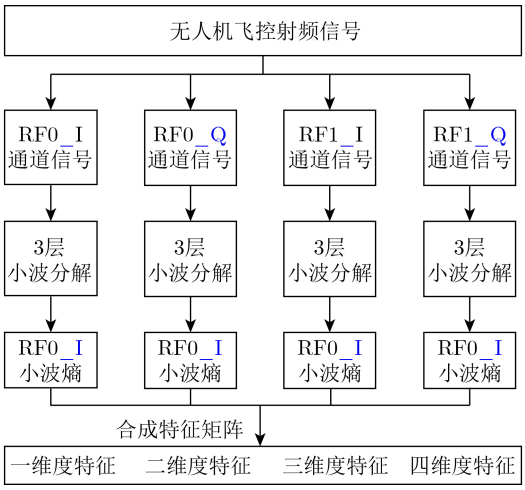

图 3 四维小波熵特征矩阵结构示意图

表 1 F检验结果

特征通道	F检验返回p值	结论
RF0_I	1.55×10^{-7}	拒绝原假设，接受备择假设
RF0_Q	1.16×10^{-7}	拒绝原假设，接受备择假设
RF1_I	1.94×10^{-9}	拒绝原假设，接受备择假设
RF1_Q	1.04×10^{-12}	拒绝原假设，接受备择假设

$$x_{i,j}^{\text{new}} = x_{i,j} + G\times(x_{k,j} - r\times x_{i,j}) \tag{9}$$

$$X_i = \begin{cases} x_{i,j} + G\times(x_{k,j} - \alpha\times x_{i,j}), F_i^{\text{new}} < F_i \\ x_{i,j} + G\times(x_{k,j} - \beta\times x_{i,j}), \text{其他} \end{cases} \tag{10}$$

其中，X_i表示第i只蔗鼠即将更新的状态或新的位置，$x_{i,j}^{\text{new}}$表示第i只蔗鼠在第j维度的值，$x_{i,j}$表示蔗鼠现在的位置，F_i为目标函数值。

开发阶段。繁殖季节因生境而异，通常发生在雨季。众所周知，雄性在繁殖季节会脱离群体。假设是，一旦群体分开，觅食活动集中在食物来源丰富的地区

$$x_{i,j}^{\text{new}} = x_{i,j} + C\times(x_{k,j} - \mu\times x_{m,j}) \tag{11}$$

为验证GCRA在函数寻最优值的能力，选取Simon Fraser大学开源函数库中的函数ACKLEY FUNCTION，该函数表达式为

$$f(x) = -a\times\exp\left(-b\times\sqrt{\frac{1}{d}\sum_{i=1}^{d}x_i^2}\right) - \exp\left(-\frac{1}{d}\times\sum_{i=1}^{d}\cos(cx_i)\right) + a + \exp(1) \tag{12}$$

参数a通常与算法的探索能力有关。较大的a值可以增强算法的全局搜索能力，有助于避免陷入局部最优解；而较小的a值则更倾向于局部搜索，提高收敛速度。在无人机射频信号识别问题中，选择a=20可能是为了在保证一定全局搜索能力的同时，不过分牺牲收敛速度。参数b可能与觅食行为的概率或强度相关。它影响到个体在搜索空间中的移动模式，该值能够有效地模拟觅食行为，从而引导算法更快地找到最优解，较低的b值可使算法更加专注于已知的食物来源区域，而较高的b 值则会增加对未知区域的探索概率。综合多次实验结果，参数设置为$a=20$, $b=0.2$，维度$d=2$。图4所示为GCRA寻优函数ACKLEY FUNCTION最小值的结果。

ACKLEY函数的理论最小值在自变量取值(0,0)时，取得最小值0。

支持向量机(Support Vector Machine, SVM)具有坚实的理论基础，与传统的机器学习方法相比，能够很好地处理小样本、 非线性以及高维模式识别问题，同时采用的结构风险最小化原则在机器学习的学习性能和泛化性能之间起到了很好的平衡作用。选取SVM作为分类器对无人机飞控射频信号进行分类识别，同时使用GCRA对SVM的参数，包括惩罚参数C和高斯核函数参数σ。优化过程的算法流程图如图5所示。

GCRA优化SVM惩罚参数C和高斯核函数参数σ，以分类的错误率作为适应度，设置迭代次数

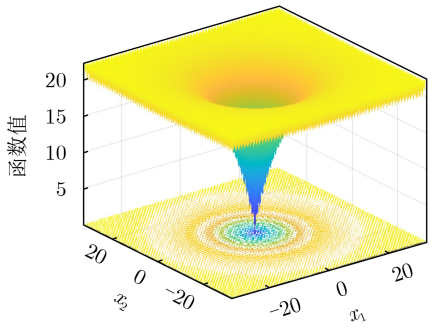

(a) ACKLEY函数3维图

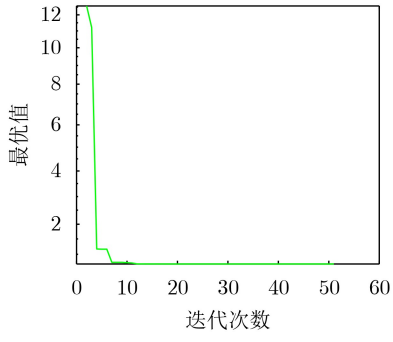

(b) GCRA寻优迭代次数与最优值关系图

图 4 GCRA搜寻函数最优值结果

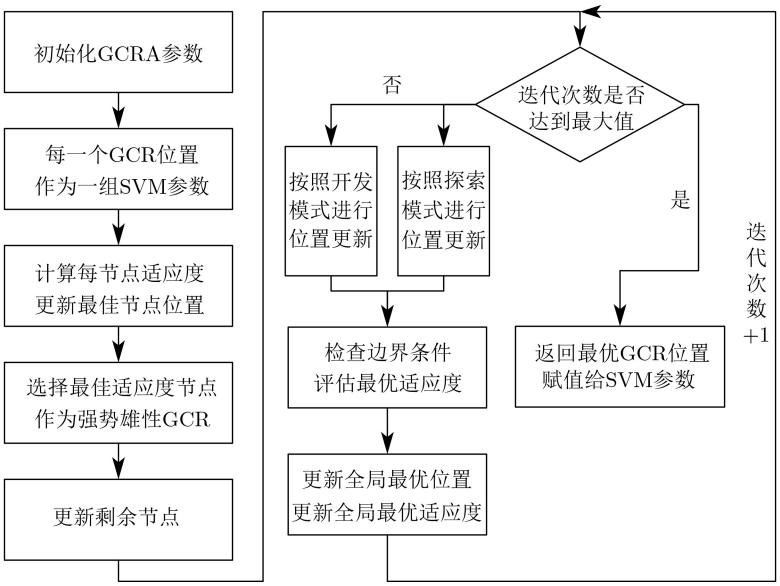

图 5 GCRA优化SVM参数算法流程图

100次，生成随着迭代次数增加，适应度的变化趋势曲线，如图6所示。其中，以优化后的SVM对学习样本的分类识别错误率作为适应度。由图6可以看出，随着迭代次数的增加，适应度呈现明显的下降趋势，且下降在迭代次数50次以内时变化最显著，最终的适应度稳定在大概0.03的水平。

选取GCRA优化后的SVM作为最终的分类器，对用于测试的无人机飞控射频信号特征矩阵进行分类识别。在算法验证过程中，选取6种型号无人机飞控射频信号进行测试，分别为DJ Phantom 3, DJI AVATA, DJI MATRICE 200, DJI Air 2S, DJI Mini 3 Pro和DJI Inspire 2。为了避免测试顺序以及测试样本选取对最终结果的影响，采用10-折交叉检验法进行算法测试验证，每种型号的无人机选取1 000个样本，将1 000个样本平均等分为10等份，每一份样本中包含共计100个测试样本，采用“循环学习-循环测试”的方式进行实验，即首选选取10等份中的其中1份作为测试样本，其余9份作为学习样本，然后选取另外1份作为测试样本，另外9份作为学习样本，以此类推。10次循环之后，统计共计1 000个测试样本测试结果的均值，作为最终的结果。图7所示为经过10-折交叉验证之后，共计1 000个测试样本的最终测试结果混淆矩阵。

根据测试结果，统计生成表2，表格中评价所提方法的指标包括识别准确率和方差，其中，识别准确率是根据混淆矩阵中真实型号和分类型号正确样本个数计算生成，方差为10-折交叉验证不同测试次数的统计方差，由表2可以看出，所提方法在测试样本集合中表现出较高的识别准确率，6种型号的无人机识别准确率都在97%以上，其中最高的

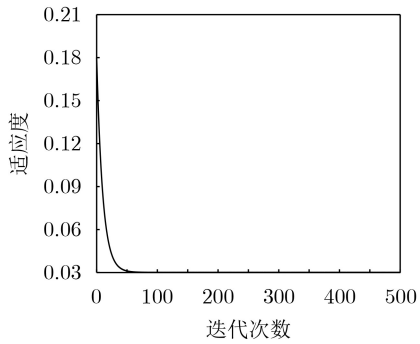

图 6 GCRA优化SVM适应度变化曲线

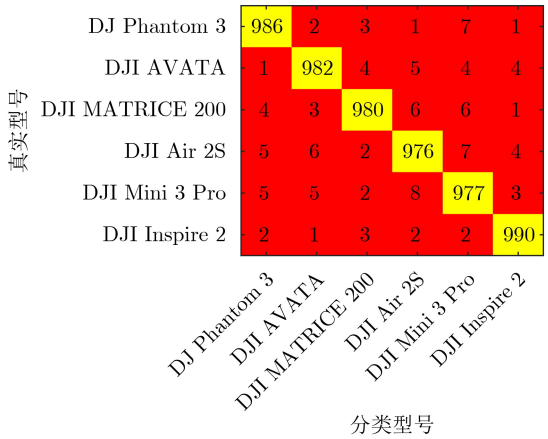

图 7 6种型号无人机射频信号分类混淆矩阵

识别准确率达到99.0%，统计方差均极小，表明所提方法性能稳定，测试结果不受实验顺序和次数的影响。

4.3 对照试验

为了验证GCRA对SVM参数进行优化后，经优化的支持向量机对无人机飞控射频信号分类识别的有效性，选取未经优化的SVM、粒子群算法优

表 2 6种型号无人机飞控射频信号分类准确率

型号	测试正确样本数	识别准确率±方差
DJ Phantom 3	986	98.6%±0.000 13
DJI AVATA	982	98.2%±0.000 21
DJI MATRICE 200	980	98.0%±0.000 42
DJI Air 2S	976	97.6%±0.000 14
DJI Mini 3 Pro	977	97.7%±0.000 46
DJI Inspire2	990	99.0%±0.000 62

化的支持向量机(Particle Swarm Optimization-based Support Vector Machine, PSO-SVM)、遗传算法优化的支持向量机(Genetic Algorithm optimized Support Vector Machine, GA-SVM)和灰狼算法优化的支持向量机(Grey Wolf Algorithm Optimized Support Vector Machine, GWO-SVM)进行算法对比。对照实验选取DJ Phantom 3, DJI AVATA, DJI MATRICE 200, DJI Air 2S, DJI Mini 3 Pro和DJI Inspire 2这6种型号的无人机的飞控射频信号为测试对象，经优化的SVM在迭代次数0～100次中选取性能最优的迭代次数，未经优化的SVM选用MATLAB中自带的LIBSVM工具箱进行实现。

表3展示了不同模型在6种无人机型号上的分类准确率。可以看出，基于GCRA优化的SVM在大多数情况下表现最佳，其平均准确率达到98.5%，高于未优化的SVM(平均准确率为91.7%)和其他优化算法优化的SVM(PSO-SVM平均准确率为94.7%，GA-SVM平均准确率为94.2%，GWO-SVM平均准确率为95.6%)。由表可知所提的GCRA-SVM方法，相比于SVM, PSO-SVM, GA-SVM和GWO-SVM均具有更高的识别准确率，且统计方差较小，算法的稳定性更好。

表 3 对照试验结果

模型选择	DJ Phantom 3	DJI AVATA	DJI MATRICE 200	DJI Air 2S	DJI Mini 3 Pro	DJI Inspire 2	平均准确率±方差
SVM	92.3%	91.8%	91.5%	91.1%	91.3%	92.5%	91.7%±0.000 49
PSO-SVM	95.2%	94.8%	94.5%	94.1%	94.3%	95.5%	94.7%±0.000 13
GA-SVM	94.9%	94.4%	94.1%	93.8%	93.9%	95.0%	94.2%±0.000 49
GWO-SVM	96.1%	95.7%	95.3%	95.0%	95.2%	96.5%	95.6%±0.000 72
GCRA-SVM	98.6%	98.2%	98.0%	97.6%	97.7%	99.0%	98.5%±0.000 32

5 结论

为提升对于无人机的飞行监管，对于无人机飞控射频信号进行准确的分类识别，本文提出一种以小波熵理论为特征提取依据，以优化支持向量机为分类器的无人机射频信号分类识别方法。通过对公开数据集种的数据进行测试验证，可以得到以下结论：

(1)基于小波熵理论的特征提取方法，可以对6种类型的无人机飞控射频信号进行显著区分，具备分类问题中对样本特征的差异显著性的要求；

(2)基于GCRA优化SVM后作为分类器，对6种类型无人机飞控射频信号进行分类，分类效果较好，分类识别准确率普遍在97%以上，最优可达到99%。

参 考 文 献

[1] 邱小剑, 骆博雅, 付珍, 等. 国内外反无人机技术发展综述[J]. 战术导弹技术, 2024(5): 63–73,98. doi: 10.16358/j.issn.1009-1300.20240095.
QIU Xiaojian, LUO Boya, FU Zhen, *et al*. An overview on development of domestic and foreign anti-UAV technology[J]. *Tactical Missile Technology*, 2024(5): 63–73,98. doi: 10.16358/j.issn.1009-1300.20240095.

[2] 付鑫, 赵然, 梁延峰, 等. 反无人机蜂群技术发展综述[J]. 中国电子科学研究院学报, 2022, 17(5): 421–428. doi: 10.3969/j.issn.1673-5692.2022.05.003.
FU Xin, ZHAO Ran, LIANG Yanfeng, *et al*. Review on the development of anti UAV bee colony technology[J]. *Journal of China Academy of Electronics and Information Technology*, 2022, 17(5): 421–428. doi: 10.3969/j.issn.1673-5692.2022.05.003.

[3] SHAKHATREH H, SAWALMEH A, HAYAJNEH K F, *et al*. A systematic review of interference mitigation techniques in current and future UAV-Assisted wireless networks[J]. *IEEE Open Journal of the Communications Society*, 2024, 5: 2815–2846. doi: 10.1109/OJCOMS.2024.3392623.

[4] CHENG Nan, WU Shen, WANG Xiucheng, *et al*. AI for UAV-Assisted IoT applications: A comprehensive review[J]. *IEEE Internet of Things Journal*, 2023, 10(16): 14438–14461. doi: 10.1109/JIOT.2023.3268316.

[5] SAVKIN A V and HUANG Hailong. A method for optimized deployment of a network of surveillance aerial drones[J]. *IEEE Systems Journal*, 2019, 13(4): 4474–4477. doi: 10.1109/JSYST.2019.2910080.

[6] 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. doi: 10.1109/TVT.2020.2964110.

[7] BERA B, DAS A K, GARG S, *et al*. Access control protocol for battlefield surveillance in drone-assisted IoT environment[J]. *IEEE Internet of Things Journal*, 2022, 9(4): 2708–2721. doi: 10.1109/JIOT.2020.3049003.

[8] NGUYEN P, TRUONG H, RAVINDRANATHAN M, *et al*. Matthan: Drone presence detection by identifying physical signatures in the drone's RF communication[C]. The 15th Annual International Conference on Mobile Systems, Applications, and Services, New York, USA, 2017: 211–224. doi: 10.1145/3081333.3081354.

[9] DE WIT J J M, HARMANNY R I A, and PRÉMEL-CABIC G. Micro-Doppler analysis of small UAVs[C]. 2012 9th European Radar Conference, Amsterdam, Netherlands, 2012: 210–213.

[10] UNLU E, ZENOU E, RIVIERE N, *et al*. An autonomous drone surveillance and tracking architecture[C]. 2019 Autonomous Vehicles and Machines Conference, San Francisco, USA, 2019: 35.

[11] 张瑞鑫, 黎宁, 张夏夏, 等. 基于优化CenterNet的低空无人机检测方法[J]. 北京航空航天大学学报, 2022, 48(11): 2335–2344. doi: 10.13700/j.bh.1001-5965.2021.0108.
ZHANG Ruixin, LI Ning, ZHANG Xiaxia, *et al*. Low-altitude UAV detection method based on optimized CenterNet[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2022, 48(11): 2335–2344. doi: 10.13700/j.bh.1001-5965.2021.0108.

[12] 聂伟, 戴琪霏, 杨小龙, 等. 基于多维信号特征的无人机探测识别方法[J]. 电子与信息学报, 2024, 46(3): 1089–1099. doi: 10.11999/JEIT230302.
NIE Wei, DAI Qifei, YANG Xiaolong, *et al*. Unmanned aerial vehicle detection and recognition method based on multi-dimensional signal feature[J]. *Journal of Electronics & Information Technology*, 2024, 46(3): 1089–1099. doi: 10.11999/JEIT230302.

[13] SHANNON C E. A mathematical theory of communication[J]. *The Bell System Technical Journal*, 1948, 27(3): 379–423. doi: 10.1002/j.1538-7305.1948.tb01338.x.

[14] 何正友, 蔡玉梅, 钱清泉. 小波熵理论及其在电力系统故障检测中的应用研究[J]. 中国电机工程学报, 2005, 25(5): 38–43. doi: 10.3321/j.issn:0258-8013.2005.05.007.
HE Zhengyou, CAI Yumei, and QIAN Qingquan. A study of wavelet entropy theory and its application in electric power system fault detection[J]. *Proceedings of the CSEE*, 2005, 25(5): 38–43. doi: 10.3321/j.issn:0258-8013.2005.05.007.

[15] BISIO I, GARIBOTTO C, LAVAGETTO F, *et al*. Blind detection: Advanced techniques for WiFi-based drone surveillance[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(1): 938–946. doi: 10.1109/TVT.2018.2884767.

[16] XIE Yuelei, JIANG Ping, GU Yi, *et al*. Dual-source detection and identification system based on UAV radio frequency signal[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 2006215. doi: 10.1109/TIM.2021.3103565.

[17] EZUMA M, ERDEN F, ANJINAPPA C K, *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*, 2020, 1: 60–76. doi: 10.1109/OJCOMS.2019.2955889.

[18] 俞宁宁, 毛盛健, 周成伟, 等. DroneRFa: 用于侦测低空无人机的大规模无人机射频信号数据集[J]. 电子与信息学报, 2024, 46(4): 1147–1156. doi: 10.11999/JEIT230570.
YU Ningning, MAO Shengjian, ZHOU Chengwei, *et al*. DroneRFa: A large-scale dataset of drone radio frequency signals for detecting low-altitude drones[J]. *Journal of Electronics & Information Technology*, 2024, 46(4): 1147–1156. doi: 10.11999/JEIT230570.

[19] 茆诗松, 程依明, 濮晓龙. 概率论与数理统计教程[M]. 2版. 北京: 高等教育出版社, 2011: 284–375.
MAO Shisong, CHENG Yiming, and PU Xiaolong. Probability and Mathematical Statistics[M]. 2nd ed. Beijing: Higher Education Press, 2011: 284–375.

[20] AGUSHAKA J O, EZUGWU A E, SAHA A K, *et al*. Greater cane rat algorithm (GCRA): A nature-inspired metaheuristic for optimization problems[J]. *Heliyon*, 2024, 10(11): e31629. doi: 10.1016/j.heliyon.2024.e31629.

刘　冰：男，博士，讲师，研究方向为信号处理，eVTOL探测与感知.
时明心：男，硕士生，研究方向为机器学习，目标探测.
刘佳琪：女，硕士生，研究方向为模式识别，未来城市空中交通系统.

责任编辑：余　蓉

Research on Unmanned Aircraft Radio Frequency Signal Recognition Algorithm Based on Wavelet Entropy Features

LIU Bing[①②] SHI Mingxin[①] LIU Jiaqi[①]

[①](*School of Transportation Science and Engineering, Civil Aviation University of China, Tianjin* 300300, *China*)

[②](*Key Laboratory of Technology and Equipment of Tianjin Urban Air Transportation System, Civil Aviation University of China, Tianjin* 300300, *China*)

Abstract:

Objective With the rapid development and broad application of Unmanned Aerial Vehicle (UAV) technology, its use in military reconnaissance, agricultural spraying, logistics, and film production presents growing challenges in signal classification and safety supervision. Accurate classification of UAV Radio Frequency (RF) signals in complex electromagnetic environments is critical for real-time flight monitoring, autonomous obstacle avoidance, and communication reliability in multi-agent coordination. However, conventional recognition methods exhibit limitations in both feature extraction and classification accuracy, particularly under interference or multipath propagation, which severely reduces recognition performance and constrains practical implementation. To address this limitation, this study proposes a recognition algorithm based on wavelet entropy features and an optimized Support Vector Machine (SVM). The method enhances classification accuracy and robustness by extracting wavelet entropy features from UAV RF signals and optimizing SVM parameters using the Great Cane Rat Optimization Algorithm (GCRA). The proposed approach offers a reliable strategy for UAV signal identification under complex electromagnetic conditions. The results contribute to UAV airspace regulation and unauthorized flight detection and establish a foundation for future applications, including autonomous navigation and intelligent route planning. This work holds both theoretical value and practical relevance for supporting the secure and standardized advancement of UAV systems.

Methods This study adopts a systematic approach to achieve accurate classification and recognition of UAV RF signals, including four key stages: data acquisition, feature extraction, classifier design, and performance verification. First, the publicly available DroneRFa dataset is selected as the experimental dataset. It contains RF signals from 24 mainstream UAV models (e.g., DJI Phantom 3, DJI Inspire 2) across three ISM frequency bands—915 MHz, 2.4 GHz, and 5.8 GHz (Fig. 1). Data collection follows a "pick-store-pick-store" protocol to preserve signal integrity and ensure accurate classification. During preprocessing, 50,000 sampling points are extracted from each channel (RF0_I, RF0_Q, RF1_I, RF1_Q), balancing data continuity and feature representativeness under hardware read/write constraints. Signal magnitudes are normalized to eliminate amplitude-related bias. For feature extraction, a three-level wavelet transform using the Daubechies "db4" wavelet is applied to decompose the signal at multiple scales. A four-dimensional feature matrix is constructed by computing wavelet spectral entropy (Figs. 2 and 3), which captures both time-frequency characteristics and energy distribution. Feature differences among UAV models are confirmed by F-test analysis (Table 1), establishing a robust foundation for classification. In the classifier design stage, the GCRA is applied to optimize the penalty parameter C and Gaussian kernel parameter σ of the SVM. The classification error rate serves as the fitness function during optimization (Fig. 5). Inspired by the foraging behavior of cane rats, GCRA offers improved global search performance. Finally, algorithm performance is evaluated using 10-fold cross-validation and benchmarked against unoptimized SVM, PSO-SVM, GA-SVM, and GWO-SVM (Table 3), demonstrating the robustness and reliability of the proposed method.

Results and Discussions This study yields several key findings. For wavelet entropy feature extraction, the F-test confirms that features from all four channels are statistically significant ($p < 0.05$), demonstrating their effectiveness in distinguishing among UAV models (Table 1). In classifier optimization, the GCRA exhibits strong parameter search capability, with fitness convergence achieved within 50 iterations at approximately 0.03 (Fig. 6). The optimized SVM classifier reaches an average recognition accuracy of 98.5%, representing a 6.8

percentage point improvement over the traditional SVM (Table 3). At the individual model level, the highest recognition accuracy is observed for DJI Inspire 2 (99.0%), with all other models exceeding 97% (Table 2). Confusion matrix analysis indicates that all misclassification rates are below 3% (Table2, Fig. 7). Notably, under identical experimental conditions, GCRA-SVM outperforms other optimization algorithms—achieving higher accuracy than PSO-SVM (94.7%) and GA-SVM (94.2%)—with lower variance ($\pm$0.00032), indicating greater stability (Table 3). These results validate the discriminative power of wavelet entropy features and highlight the enhanced performance and robustness of GCRA-based SVM optimization.

Conclusions　Through systematic theoretical analysis and experimental validation, this study reaches several key conclusions. The wavelet entropy-based feature extraction method effectively captures the time-frequency characteristics of UAV RF signals. By employing multi-scale decomposition and energy distribution analysis, it accurately identifies the unique signal features of various UAV models. Statistical tests confirm significant differences among the features of different UAV categories, providing a solid foundation for feature selection in UAV identification. The optimization of SVM parameters using the GCRA substantially enhances classification performance, achieving an average accuracy of 98.5% and a peak of 99% on the DroneRFa dataset, with excellent stability. This method addresses the technical challenge of UAV RF signal recognition in complex electromagnetic environments, with performance metrics fully meeting practical application needs. The findings offer a reliable technical solution for UAV flight supervision and lay the groundwork for advanced applications such as autonomous obstacle avoidance. Future research may focus on evaluating the method's performance in high-noise environments and exploring fusion strategies with other models. Overall, this study provides significant contributions both in terms of theoretical innovation and engineering application.

Key words: Wavelet entropy; Optimization neural network; Unmanned Aerial Vehicle Radio Frequency (UAV RF) signal; Recognition algorithm