

基于改进残差神经网络的无人机信号识别方法

王硕哲 郝东来* 李民靖 马思语
西京学院, 中国·陕西 西安 710123

摘要: 无人机 (UAV) 射频 (RF) 信号检测在低空安防应用中具优势, 但在复杂环境下传统方法鲁棒性有限。本文提出一种基于改进残差神经网络的无人机信号识别方法, 采用短时傅里叶变换 (STFT) 提取特征, 结合分组卷积与跨层级跳跃连接, 提升信号检测、机型分类与操作模式识别性能。实验表明, 该方法检测准确率达 99.94%, 分类为 86.66%, 操作模式识别为 80.13%, 同时降低了参数和计算开销。研究为复杂环境下无人机智能识别提供了有效支持。
关键词: 无人机射频信号; 短时傅里叶变换; 改进残差神经网络; 识别与分类

UAV signal recognition method based on improved residual neural network

Wang Shuozhe Hao Donglai* Li Minjing Ma Siyu

Xijing University, Xi'an, Shaanxi 710123, China

Abstract: Drone radio frequency (RF) signal detection demonstrates advantages in low-altitude security applications, yet traditional methods exhibit limited robustness in complex environments. This paper proposes an improved residual neural network-based UAV signal recognition method. By employing short-time Fourier transform (STFT) for feature extraction and integrating grouped convolution with cross-level skip connections, the approach enhances performance in signal detection, aircraft type classification, and operation mode recognition. Experimental results show the method achieves 99.94% detection accuracy, 86.66% classification accuracy, and 80.13% operation mode recognition accuracy, while reducing parameters and computational costs. The study provides effective support for intelligent UAV identification in complex environments.

Keywords: UAV RF signals; Short-time fourier transform; Improved residual neural network; Recognition and classification

0 前言

低空经济发展推动无人机应用, 但也带来安全隐患。传统侦测技术如雷达、视觉与声学方法存在环境依赖性强、抗干扰差等问题。基于射频感知的深度学习成为热点, 但在动态调制和计算复杂度上仍受限。论文提出改进残差神经网络 (ResNet), 利用 STFT 提取特征, 通过分组卷积与跨层级特征融合实现轻量化与高鲁棒性的平衡, 解决无人机检测与分类难题。

1 数据集介绍与数据预处理

1.1 数据集获取

实验采用 IEEE DroneDetect 开源数据集, 并结合自主采集的 49 种无人机射频信号, 共包含 4 类干扰环境 (BLUE、WIFI、BOTH、CLEAN)、3 种飞行模式 (FLY、HO、ON) 下的 588 类信号。

1.2 数据集预处理方案

采集信号以交织形式存储, 实部与虚部交替排列, 表示正交分量:

$$s(t) = I(t) + jQ(t) \quad (1)$$

它们可以通过欧拉公式表示为:

$$X = a + jb = |x|e^{j\theta} \quad (2)$$

其中, a 为实部, b 为虚部, j 为虚数单位。

1.3 数据集样本时频分析

在不同干扰环境下绘制信号时频图 (见图 1), 结果显示干扰环境下信号频率波动显著, 无干扰时信号平稳规整。




图 1 不同环境不同状态下无人机信号时频图

2 算法设计与实现

2.1 基于短时傅里叶变换的无人机射频信号特征提取

信号经傅里叶变换得到频谱:

$$fft_data = |fft(data)| \quad (3)$$

接下来根据数据的长度 $data_len$ 和采样率 fs 构建频率向量:

$$data_len = length(data), fs = 1 \quad (4)$$

频率向量的计算方式是利用采样率和数据长度确定频率分辨率和最大频率，从而构建一个频率范围对应的数组：

$$f = \frac{(0: data_len - 1) \times fs}{data_len} \quad (5)$$

在构建了频率向量之后，可以选择感兴趣的频率范围。这一过程涉及从频率向量中提取相关的索引，这些索引对应于傅里叶变换结果中的特定频率成分：

$$freq_index = find(f \geq freq_range(1) \text{ and } f \leq freq_range(2)) \quad (6)$$

通过这些索引，可以从傅里叶变换的结果中提取出在这些频率范围内的幅值数据，对提取出的幅值进行归一化处理，将其缩放至 0 到 1 的范围：

$$feature_vector = \frac{fft_data(freq_index)}{\max(fft_data(freq_index))} \quad (7)$$

最后，将归一化后的幅值数据重塑为特征矩阵 `feature_matrix`。特征矩阵是用于后续分析和模型训练的结构化数据形式：

$$feature_matrix = reshape(feature_vector, [1, length(feature_vector)]) \quad (8)$$

最终形成特征矩阵 `feature_matrix`，作为神经网络输入。

2.2 基于改进的残差神经网络实验

2.2.1 实验设计

设计基于分组卷积和跨层级跳跃结构的改进残差网络，保持梯度稳定并提取多尺度特征。

2.2.2 实验流程

第一步，准备数据集。

①准备无人机射频信号数据。

$$X_i = \frac{X_i - x_{min}}{x_{max} - x_{min}} \quad (9)$$

②进行分组一维卷积。

分组一维卷积特征提取结构见图 2。




图 2 分组一维卷积特征提取结构

$$C_{x,y} = \sum_i W_i M_i + b \quad (10)$$

批量归一化操作：

$$C_{x,y}^* = \frac{C_{x,y} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (11)$$

归一化层通过对归一化的值进行移位和缩放，来处理具有零均值和非最优方差的输入，将其传递到归一化层后面的层：

$$G_{x,y} = kC_{x,y}^* + l \quad (12)$$

eLU 隐藏层激活：

$$O_{x,y} = eLU(V_{x,y}) = \begin{cases} V_{x,y}, & V_{x,y} \geq 0 \\ \alpha(e^{V_{x,y}} - 1), & V_{x,y} < 0 \end{cases} \quad (13)$$

第二步，为了有效处理梯度流来提高整体系统准确性，搭建了一种多层次跳跃连接结构：

①加法层跳跃连接处理。

$$F_{add}^i = F_{pi} + F_{g(i+1)} \quad (14)$$

逐元素相加层不会改变特征维度。提出的多级跳连允许在不同的特征层级中保留大部分的梯度信息。

$$F_{g(i+1)}^* = P_{avg}(F_{g(i+1)}), i = 1, \dots, 5 \quad (15)$$

式中： F_{multi} 为深度串联堆叠， \mathcal{D} 为连接操作。

$$F_{multi} = \mathcal{D}(F_{g2}^*, F_{g3}^*, F_{g4}^*, F_{g5}^*, F_{g6}^*) \quad (16)$$

连接层会将具有相同高度和宽度的输入沿深度（或通道）维度进行聚合。

$$F_{final} = \mathcal{D}(F_{multi}, F_{add}^5) \quad (17)$$

F_{final} 包含多个尺度的信号特征合成信息，然后输入 n 个神经元定义的全连接层，全连接层神经元数是根据数据集中类的数量来确定的。

$$P_j = \frac{e^{S_j}}{\sum_{j=1}^n e^{S_j}} \quad (18)$$

网络根据 softmax 函数的输出，将每个输入分配给 n 个互斥类中的一个，并用拉普拉斯变换计算出多分类的交叉熵损失：

$$\mathcal{L} = - \sum_{i=1}^N \sum_{j=1}^n V_{ij} \ln(U_{ij}) \quad (19)$$

第三步，交叉训练微调网络构建检测模型。

第四步，测试系统的检测效果。

2.2.3 实验分析

验证结果显示：无人机存在检测准确率 99.94%，分类 86.66%，操作模式 80.13%（见图 3）。与三种对比模型 A、B、C 相比，本方法在低复杂度下保持较高精度，见表 1。

在激活函数对比中，eLU 整体准确率较优（见表 2）。




图 3 验证准确度对比折线图

表 1 不同模型对比分析表

模型	模型结构				识别准确率 (%)			复杂度	迭代轮数
	标准卷积	分组卷积	跳跃连接	多间隙结构	无人机检测	无人机分类	操作识别	参数数量	
A 模型	有	无	无	无	99.63	81.64	82.78	50K	10
B 模型	无	有	无	无	99.58	81.23	84.21	8.4K	10
C 模型	无	有	有	无	99.61	84.58	83.12	8.4K	10
本模型	无	有	有	有	99.94	86.66	80.13	11K	10

表 2 不同激活函数的模型识别准确率对比表

隐藏层激活	识别准确率 (%)			迭代轮数
	无人机检测	无人机分类	操作识别	
ReLU	98.69	85.91	74.14	10
eLU	99.94	86.66	80.13	10
LeakyReLU	99.77	84.80	83.36	10
Tanh	98.97	82.73	76.42	10

3 结语

针对传统方法在复杂环境下的局限，论文通过改进残差神经网络识别无人机射频信号，提升了检测精度与鲁棒性，同时降低了计算复杂度。实验验证了跨层级特征融合和分组卷积的有效性。未来将扩充数据集并优化模型，为低空安防提供技术支撑。

参考文献：

[1] 赵刚.低空经济安全防护研究与应用[J].电信工程技术与标准

化,2025,38(2):1-6+18.

[2] Kılıç R, Kumbasar N, Oral E A, et al. Drone classification using RF signal based spectral features[J]. Engineering Science and Technology, an International Journal,2022(28):101028.

[3] Al-Sa'd F M, Al-Ali A, Mohamed A, et al. RF-based drone detection and identification using deep learning approaches: An initiative towards a large open source drone database[J]. Future Generation Computer Systems,2019:10086-97.

[4] 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.

作者简介: 王硕哲(1998-),男,中国河南焦作人,硕士,从事计算机智能技术与应用、智能通信研究。

通信作者: 郝东来(1974-),男,中国陕西咸阳人,博士,副教授,从事人工智能技术与应用、智能通信研究。