

基于改进神经网络的 UAV 射频信号识别研究

陈恩泽¹ 罗保诚¹ 黄 琴¹ 李广选¹ 李 立²

CHEN Enze LUO Baocheng HUANG Qin LI Guangxuan LI Li

摘 要

针对无人机射频信号检测识别性能不足、传统算法在复杂场景下识别效果不佳的问题,文章开展了针对性优化研究。实验以 DroneRFa 大规模无人机射频信号数据集为基础,通过短时傅里叶变换(STFT)对原始射频信号进行处理,构建标准化标注时频图数据集,为后续算法测试提供可靠数据支撑。为解决传统识别算法的局限性,设计两种改进型识别算法,分别为 PCA-CNN-SVM 混合算法与 TransRNetDNN 算法。其中 PCA-CNN-SVM 较传统 SVM 准确率提升 15%;TransRNetDNN 首次结合自注意力机制与残差神经网络,将传统 DNN 算法 84% 的准确率提升至 94% 左右。实验结果表明,两种算法识别效果得到明显提升,能够有效地提取复杂环境中无人机射频信号时频图像的信号特征,可适用于无人机监测和识别。

关键词

DroneRFa; 射频信号; PCA-CNN-SVM; TransRNetDNN; 神经网络

doi: 10.3969/j.issn.1672-9528.2026.02.040

0 引言

近年来,无人机技术在军事、物流等领域广泛应用,市场规模快速增长。DroneII 数据显示,2024 年全球无人机市场规模达 392 亿美元,预计 2028 年将达 520 亿美元(CAGR 7.8%)。与此同时,无人机的安全隐患日益突出,美国联邦航空管理局(FAA)的报告显示,无人机与载人飞机的危险接近事件年增长率为 41%,其中 78% 涉及非法操控,非法无人机的识别问题亟待解决。

当前主流无人机监测手段包括光学识别、雷达探测和射频指纹识别。光学方法依赖图像信息,受光照和遮挡影响大,夜间性能下降^[1]。雷达具备全天候能力,但难以准确识别低空小型无人机^[2]。而射频识别凭借非协作式、全天候优势成为研究热点^[3]。为解决上述问题,研究者们开始引入深度学习技术,Wang 等^[4]利用短时傅里叶变换将无人机信号转换为时频图像,并通过设计 CNN 网络自动提取图像中的判别性特征,同时结合迁移学习优化模型。最终在公开数据集上实现了 90% 以上的无人机信号分类准确率,优于传统手工特征与浅层机器学习模型。Li 等^[5]将无线信号视为时序序列,引入 Transformer 架构并设计混合编码器结构,通过自注

意力机制捕捉信号全局依赖,结合位置编码保留时序信息。在 OFDM 信号、蓝牙信号等序列分类任务中,模型准确率比 LSTM、GRU 等传统时序模型提升 15%~20%,且计算效率更高。Hasan^[6]采用 CNN 自动学习射频信号的时频域深层特征,并将其输入 SVM 分类器,同时利用数据增强与正则化扩充小样本数据集。在样本量减少 50% 的情况下,分类准确率比单一 CNN 或 SVM 模型提升 10%~15%,在军事通信、频谱监测等数据稀缺场景表现出色。

基于上述背景,本文提出了两种创新性的神经网络架构:一是 PCA+CNN+SVM 结合方案,通过 PCA 对 CNN 权值做预处理,利用 CNN 提取深度特征,再借助 SVM 提升小样本场景下的分类稳定性;二是首次提出 TransRNetDNN 算法模型,通过 Transformer 对时序信息进行建模,利用 ResNet 提取时频特征,最终由 DNN 完成分类任务。实验表明,TransRNetDNN 在不同场景下均表现优异,识别准确率提升至 94%,特别在小样本场景下较传统方法提升 10%,为复杂电磁环境下的无人机射频识别提供新方案。

1 自注意力机制与神经网络理论

1.1 自注意力机制

自注意力机制是 Transformer 的核心,特别适用于处理视频帧序列等时序数据。给定输入视频帧序列 $X \in \mathbf{R}^{T \times H \times W \times C}$ (T 为帧数; $H \times W$ 为分辨率; C 为通道数),首先通过空间编码将其转换为特征序列 $F \in \mathbf{R}^{T \times d}$,然后进行计算:

1. 湖南工商大学智能工程与智能制造学院 湖南长沙 410205

2. 长沙市房屋交易管理中心 湖南长沙 410205

[基金项目] 国家级大学生创新训练项目“基于软件无线电的无人机侦测识别系统设计”(S202410554120)

(1) 特征投影：将特征序列分别投影为查询、键和值：

$$Q = FW^Q, K = FW^K, V = FW^V \quad (1)$$

式中： $W^Q, W^K, W^V \in \mathbb{R}^{d \times d_k}$ 为投影矩阵。

(2) 注意力计算：计算帧间注意力权重：

$$A = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) \quad (2)$$

式中：权重特征矩阵 $A \in \mathbb{R}^{T \times T}$ 表示帧间的相关性。

(3) 特征融合：通过加权求和获取融合后的特征：

$$Z = A \cdot V \quad (3)$$

最终输出表留原始结构输出结合残差连接和层归一化，提升表达稳定性。

在射频信号处理中，自注意力机制能够有效捕捉时域与频域之间的耦合关系，有助于提取关键频段的时序特征，提升识别性能。

1.2 神经网络模型

卷积神经网络（CNN）广泛用于处理图像类任务，依托局部连接与权重共享机制，提取空间结构特征。

设输入频谱图像为 $I \in \mathbb{R}^{H \times W}$ ，卷积层使用卷积核 $K \in \mathbb{R}^{k \times k}$ 进行局部特征提取：

$$Y_{i,j} = \sum_{m=1}^k \sum_{n=1}^k I_{i+m, j+n} \cdot K_{m,n} \quad (4)$$

CNN 主要由卷积层、池化层和全连接层组成，具备空间特征提取、下采样与高层语义映射能力。如图 1 所示，CNN 逐层提取特征，适用于图像局部结构分析。




图 1 CNN 神经网络模型结构图

深度神经网络（DNN）是多层全连接前馈网络。对于视频图像提取的特征向量 $X \in \mathbb{R}^d$ ，DNN 通过非线性映射逼近复杂的函数关系：

$$h(l) = f(W^{(l)}h^{(l-1)} + b^{(l)}) \quad (5)$$

式中： f 是激活函数，通过逐层组合，DNN 能从低级特征构建出高级抽象表示，提高特征表达、泛化、复杂任务处理、非线性映射及抗干扰能力。

如图 2 所示，DNN 结构强调了逐层组合与特征抽象，适用于全局特征建模和模式识别任务^[7]。

ResNet 在传统 DNN 基础上引入跳跃连接^[8]，以学习残差函数而非直接学习原始映射：

$$y = F(x, \{W\}) + x \quad (6)$$

式中： $F(x)$ 表示残差模块； x 表示输入； y 表示输出。




图 2 DNN 神经模型结构图

如图 3 所示，ResNet 中的恒等映射结构有效缓解梯度消失问题，提升训练稳定性和泛化性能，适用于高分辨率视频和复杂场景建模。




图 3 ResNet 神经模型基础结构图

虽然深度学习网络具有强大的特征提取能力，但在分类任务中，使用支持向量机（support vector machine, SVM）作为分类器也具有显著优势。SVM 能更好地处理高维稀疏特征，具备良好的泛化能力。因此，常采用“深度特征提取+SVM 分类”的方式以提高识别准确率与稳定性。

2 实验数据分析与预处理

2.1 数据集介绍

实验采用用于侦测低空无人机的大规模无人机射频信号数据集（DroneRFa），包含多平台无人机的 RF 信号数据，适用于频谱分析、信号检测、干扰建模及分类等任务。所有数据以 .mat 格式存储，文件名通过二进制编码规则标注标签：前缀字母“T”（无人机型号）、“D”（探测距离）、“S”（信号片段序号）后跟二进制序列，如“T0010_D01_S1110.mat”表示距离 40~80 m 的 DJI Phantom 4 Pro 在 5.8 GHz ISM 频段的信号片段。每个文件包含四组双精度浮点型通道数据：RF0_I/Q（第一接收机通道的同相/正交分量）和 RF1_I/Q（第二通道）^[9]。数据集为无人机信号处理研究提供了标准化实验材料，支持多场景下的无线通信分析。关于二进制编码与实际标签之间的对应规则如表 1 所示。

表 1 对应关系

前缀字符	二进制编码	含义说明 (T 型号 /D 探测距离 / S 信号片段)
T	0000	背景 (含蓝牙、Wi-Fi、噪声)
T	0001	DJI Phantom 3
T	0010	DJI Phantom 4 Pro
T	0011	DJI MATRICE 200
T	0100	DJI MATRICE 100
T	0101	DJI Air 2S
T	0110	DJI Mini 3 Pro
T	0111	DJI Inspire 2
T	1000	DJI Mavic Pro
T	1001	DJI Mini 2
T	1010	DJI Mavic 3
T	1011	DJI MATRICE 300
T	1100	DJI Phantom 4 Pro RTK
D	01	40~80 m
D	10	80~150 m
T	1101	DJI MATRICE 30T
T	1110	DJI AVATA
T	1111	DJI 通信模块自组机
T	10000	DJI MATRICE 600 Pro
T	10001	VBar 飞控器
T	10010	FrSky X20 飞控器
T	10011	Futaba T6IZ 飞控器
T	10100	Taranis Plus 飞控器
T	10101	RadioLink AT9S 飞控器
T	10110	Futaba T14SG 飞控器
T	10111	云卓 T12 飞控器
T	11000	云卓 T10 飞控器
D	00	20~40 m
S	0000~0111	设置初始通信在 915 MHz 或 2.4 GHz
S	1000~1111	若设备支持则切换至 2.4 GHz 或 5.8 GHz

2.2 数据预处理

选用部分 DroneRFa 数据,将数据具象化为时频谱图,然后结合图像处理和机器学习数据分析技术基于时频图像完成信号检测和无人机信号识别。

通过对时域 IQ 信号采样数据进行短时傅里叶变换 (STFT) 分析^[10]。设置采样频率 100 MHz 和窗口参数,然后使用 Hamming 窗对信号进行加窗。通过 ShortTimeFFT 类计算信号的 STFT,得到频域和时间域的特征。进一步对 STFT 的幅度谱进行对数变换并归一化,最后利用图像处理技术对原图像进行降维展平,大幅减少了数据分析量^[11]。

利用上述方法构建新的数据集,无人机信号类型共 45 种,并对信号进行标注,每种信号类型均含 36 个样本,生成的标注数据集 DroneRFa-dataset 如表 2 所示。其中无人机视频图如图 4 所示。

表 2 DroneRFa-dataset 数据集 (前十种)

信号类型	样本个数
T0001_D00_S0000	36
T0001_D00_S1000	36
T0010_D00_S0000	36
T0010_D00_S1011	36
T0011_D00_S0010	36
T0011_D00_S1000	36
T0100_D00_S0010	36
T0100_D00_S1001	36
T0101_D00_S0001	36
T0101_D00_S1000	36

图 4 (a) 表示 T0001_D00_S0000 时频图为 20~40 m 远处的 DJI Phantom 3 机型无人机工作在 2.4 GHz ISM 的时频图。




图 4 本数据集中部分无人机信号时频谱灰度图

3 实验设计与结果分析

3.1 PCA-CNN-SVM 算法设计

将所有图片按照统一像素点读取组成数据集,经实验若只采用 SVM 算法对本数据集进行分类研究,得到的分类效果表现不佳,准确率最高仅达 88%。

通过深入理解卷积神经网络原理发现卷积神经网络是通过卷积层提取特征,在卷积层后使用全连接层构建分类器对提取到的特征进行分类。基于上述原理本研究采用支持向量机 (SVM) 分类器替代传统的使用全连接层的分类器方法,通过非多次迭代训练的方式实现无人机类别的判别分类^[12]。鉴于本研究未经传统卷积神经网络迭代训练的步骤,提取特征的卷积核由随机产生,存在不确定性太高和提取特征无代表性问题,为此本研究利用 CNN 与 PCA 相结合的方法^[13],用 PCA 对 CNN 权值进行预处理流程,得到卷积层所需参数。再由 SVM 分类器代替全连接层接入到展平层后,利用 SVM 分类器对卷积得到的每张图片的特征进行分类识别,算法流程图如图 5 所示。




图 5 PCA-CNN-SVM

实验表明，执行上述操作之后对本数据集的分类准确率可以达到 96% 左右。对比实验表明，采用 SVM 分类器替代全连接层的方案，效果优于训练收敛后带一定层数全连接隐藏层的卷积神经网络。本研究中的 PCA-CNN-SVM 模型，可以作为传统卷积神经网络的基础参照，对自建传统卷积神经网络模型进行评估。

3.2 TransRNetDNN 算法设计

由于深度神经网络（DNN）依靠卷积层进行特征提取，卷积操作注重局部特征的提取。但无人机射频信号图像中存在一些全局的、长距离依赖的特征，这些特征对于准确分类非常关键。本研究创新性地提出 TransRNetDNN 算法，通过融合残差网络（ResNet）的局部特征提取能力与 Transformer 的全局依赖建模优势，结合自注意力机制优化深度神经网络（DNN）的特征表示，将显著提升对多类无人机射频信号的分类性能。

TransRNetDNN 混合模型包括特征提取层、特征增强层和分类决策层。

（1）特征提取层：采用预训练 ResNet18 提取 512 维局部特征，保留其深层语义信息。

（2）特征增强层：引入多层自注意力模块（SelfAttention），通过 Query-Key-Value 机制捕捉特征间全局依赖。

（3）分类决策层：由多层全连接网络（DNN）构成，结合 BatchNorm 和 Dropout 防止过拟合。

TransRNetDNN 模型设计伪码为：

（1）定义 SelfAttention 类：

- 初始化：
 - 创建 Query、Key、Value 的全连接层
 - 定义 Softmax 归一化
 - 定义 LayerNorm 归一化
- 前向传播：
 - 计算 Q, K, V
 - 计算注意力权重： $\text{softmax}(Q * K^T / \text{sqrt}(\text{维度}))$
 - 计算加权输出：注意力权重 $* V$
 - 残差连接 + 归一化后返回结果

（2）定义 FeatureExtractor 类：

- 初始化：
 - 加载 ResNet18 预训练模型

— 去掉 ResNet18 的最后全连接层

— 前向传播：

- 输入图像通过 ResNet18 提取特征
- 返回特征向量

（3）定义 DNNWithAttention 类：

— 初始化：

- 定义全连接层：
 - fc1: 输入 $\rightarrow 2048$
 - fc2: $2048 \rightarrow 1024$
 - fc3: $1024 \rightarrow 512$
 - fc4: $512 \rightarrow 256$
 - fc5: $256 \rightarrow \text{num_classes}$

— 定义批量归一化（BN）层

— 定义自注意力模块（attn1, attn2）

— 定义激活函数：LeakyReLU(0.1)

— 定义 Dropout (0.4)

— 前向传播：

- $x \rightarrow \text{fc1} \rightarrow \text{BN} \rightarrow \text{激活} \rightarrow \text{attn1} \rightarrow \text{残差连接} \rightarrow \text{Dropout}$
- $x \rightarrow \text{fc2} \rightarrow \text{BN} \rightarrow \text{激活} \rightarrow \text{attn2} \rightarrow \text{残差连接} \rightarrow \text{Dropout}$
- $x \rightarrow \text{fc3} \rightarrow \text{BN} \rightarrow \text{激活} \rightarrow \text{Dropout}$
- $x \rightarrow \text{fc4} \rightarrow \text{激活}$
- $x \rightarrow \text{fc5}$ （输出）
- 返回最终分类结果

网络训练过程中输出的训练和验证损失曲线、训练和验证准确率曲线如图 6 所示。观察曲线图，发现随着迭代次数的增加，网络逐渐收敛。




图 6 算法训练和验证损失曲线和准确率曲线

使用测试数据集输入该算法模型进行类型识别，得到的混淆矩阵如图 7 所示。图 7 中的类别依次对应表 2 中的标注数据集类别。

3.3 模型评估

本研究构建了 PCA-CNN-SVM 和 TransRNetDNN 两种神经网络预测模型，实验数据总样本数量为 1 620，数据打乱输入模型中，随机分配训练样本 1 296 个，预测样本 324 个。通过与传统模型性能对比，评价指标如表 4 所示。




图 7 分类混淆矩阵

表 4 模型性能评价指标

模型	单位: %			
	Accuracy	Precision	Recall	F ₁ -Score
SVM	88.14	80.35	80.58	79.14
CNN	88.15	88.53	88.31	85.07
PCA-CNN-SVM	96.29	96.23	95.78	95.59
ResNet	91.85	91.18	91.67	90.33
DNN	84.77	81.80	82.50	80.18
TransRNetDNN	94.81	95.94	94.81	94.57

PCA-CNN-SVM 算法在该数据集分类实验中表现出色,准确率达到 96% 左右,远高于传统 SVM 算法(使用原图时准确率约 81%,图像增强后约 88%)。其优势在于结合了 PCA 对 CNN 权值的预处理、CNN 强大的特征提取能力以及 SVM 在小样本分类时的稳定性。PCA 预处理为 CNN 提供了更优的卷积核参数,使 CNN 能更有效地提取特征,而 SVM 替代全连接层进行分类,避免了复杂的训练过程,且在小样本情况下也能保持较高的分类准确性。与只有两层全连接隐藏层的卷积神经网络相比,PCA-CNN-SVM 效果更优,表明该算法的结构设计在处理无人机射频信号时频图数据上具有独特优势。而 TransRNetDNN 算法融合了 ResNet 的局部特征提取能力、Transformer 的全局依赖建模优势以及自注意力机制,有效提升了对多类无人机射频信号的分类性能,识别准确率可达 94% 左右,高于传统 DNN 算法的 84%。从算法结构来看,特征提取层利用预训练的 ResNet18 保留了深层语义信息,为后续分类提供了有利的特征基础;特征增强层的多层自注意力模块能够捕捉特征间的全局依赖,弥补了传统卷积操作在处理长距离依赖特征上的不足;分类决策层通过多层全连接网络结合 BatchNorm 和 Dropout 防止过拟合,提高了分类的准确性和稳定性。从训练和验证曲线可以看出,随

着迭代次数增加,网络逐渐收敛,表明算法具有良好的训练性能。

4 结语

本文针对复杂电磁环境下无人机射频信号面临的频谱泄漏、加密干扰及高虚警率等挑战,提出了两种基于时频图像的信号特征提取与识别算法。实验结果表明,在仅约 1 500 条样本的数据条件下,两种算法仍能保持超过 90% 的识别准确率,验证了所提方法在复杂环境中的鲁棒性和适应性。尽管目前研究已取得阶段性成果,但受限于数据量和场景多样性,对算法性能的进一步提升仍有较大空间。未来工作将从以下几个方面展开:一是扩充数据集规模,融合多型号无人机及更多干扰场景的射频样本,以增强模型的泛化能力;二是引入更先进的超参数优化与自动化调参技术,挖掘模型潜力;三是探索深度学习与传统信号处理方法的协同融合,提升识别效率与实时性。随着无人机技术与电磁环境的持续演进,射频识别技术也将不断发展。相信通过持续的数据积累与算法创新,所提方法将在无人机监测与防御领域发挥更大作用。

参考文献:

- [1] FU C L, WU Y S, JIN X, et al. Enhanced YOLOv7 model for aerial drone detection in complex environments[C]//2024 IEEE International Symposium on Parallel and Distributed Processing with Applications (ISPA). Piscataway: IEEE, 2024: 1385-1392.
- [2] WANG E S, SHU W S, ZHU J J, et al. Low-altitude UAV recognition and classification algorithm based on machine learning[C]//2021 IEEE 16th Conference on Industrial Electronics and Applications (ICIEA), Piscataway: IEEE, 2021: 1136-1141.
- [3] EZUMA M, ERDEN F, ANJINAPPA C K, et al. UAV detection and identification[C]//UAV Communications for 5G and Beyond. Piscataway: IEEE, 2021: 71-102.
- [4] WANG Y W, ZHONG Z J, RUI Y P, et al. Research on UAV remote control signal recognition based on time-frequency map[C]//2023 IEEE International Conference on Control, Electronics and Computer Technology (ICCECT), Piscataway: IEEE, 2023: 1093-1096.
- [5] LI W, ZHANG Y C, XU Y, et al. Classification of UAVs utilizing STFT features of RF fingerprints and ASPConv-ResNet34 network[C]//2024 10th International Conference on Computer and Communications (ICCC). Piscataway: IEEE, 2024: 1748-1752.

融合键值表示与改进注意力机制的人岗匹配模型

啜子涵¹ 薛霞²
CHUO Zihan XUE Xia

摘要

人岗匹配 (person-job fit, PJF) 是在线招聘的核心, 用于智能匹配岗位与简历。大多数现有的 PJF 方法都将此任务看作是工作描述和简历中自由文本之间的匹配, 但忽略了半结构化多元属性的贡献, 导致预测失败。基于此, 文章提出了一种全面探索 PJF 中半结构化多元属性间复杂关系的模型 SIFT, 旨在有效匹配职位和简历。首先, 将每个属性的键和值以及来源都嵌入到相同的语义空间中; 随后, 使用 MSF 模块进行有效的特征融合, 并结合 Transformer 模型和 Talking-Heads Attention 以提升模型的鲁棒性和泛化能力; 最后, 使用匹配聚合层来预测匹配程度。该研究在真实数据集 (智联招聘数据集) 上验证了 SIFT 的有效性。实验结果表明, SIFT 模型在 AUC、准确性和 F_1 分数方面总体改进分别为 3.51%、3.72% 和 0.71%。

关键词

人岗匹配; 自然语言处理; 深度学习

doi: 10.3969/j.issn.1672-9528.2026.02.041

0 引言

近年来, 求职人数不断增长, 新兴招聘平台层出不穷, 海量的岗位与简历信息在网络上呈现爆炸式增长。求职者希

望通过智能手段找到与自身职业发展契合的岗位, 而招聘方则致力于筛选出与岗位要求高度匹配的人才。然而, 传统依赖人工筛选简历的方式, 不仅效率低、耗时费力, 而且容易受到主观偏见的影响, 严重制约了人力资源管理的智能化发展。因此, 如何从简历中精准挖掘求职者的能力, 并与岗位需求进行高效匹配, 成为亟待解决的关键问题, 即人岗匹配 (person-job fit, PJF) 任务。

1. 太原师范学院 山西晋中 030600
2. 运城学院 山西运城 044000
[基金项目] 山西省基础 Research 计划资助项目 (202203021212174)

[6] HASAN M M, PANDEY A, RAJ A A B.UAV classification from micro-doppler signature-based time frequency images using SVM[C]// 2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAISS). Piscataway: IEEE, 2022: 1225-1230.
[7] 陈翔, 汪连栋, 许雄, 等. 基于 Raw I/Q 和深度学习的射频指纹识别方法综述 [J]. 雷达学报, 2023, 12(1): 214-234.
[8] 刘鸿达, 孙旭辉, 李沂滨, 等. 基于卷积神经网络的图像分类深度学习模型综述 [J]. 计算机工程与应用, 2025, 61(11): 1-21.
[9] 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.
[10] 李超群, 王金明. 基于短时傅里叶变换的无人机射频指纹分类识别 [J]. 通信技术, 2022, 55(9): 1202-1207.
[11] 程晓静, 牛慧莹. 基于时频图像的无人机信号检测识别算法研究 [J]. 信息技术, 2022(4): 170-174.
[12] 孟彩茹, 宋京, 孙明扬. 基于改进 CNN 与 SVM 的手势识

别研究 [J]. 现代电子技术, 2020, 43(22): 128-131.
[13] 李州, 汪繁荣. 基于 CNN-SVM 的变压器故障诊断方法 [J]. 现代电子技术, 2025, 48(6): 73-77.

【作者简介】

陈恩泽 (2004—), 男, 湖南常德人, 本科, 研究方向: 深度学习、信号处理。
罗保诚 (2004—), 男, 湖南怀化人, 本科, 研究方向: 信号处理、软件无线电。
黄琴 (2004—), 女, 湖南邵阳人, 本科, 研究方向: 深度学习。
李广选 (2001—), 男, 山东烟台人, 硕士研究生, 研究方向: 反无人信号侦测。
李立 (1983—), 女, 湖北武汉人, 本科, 职员, 研究方向: 数据分析处理。

(收稿日期: 2025-09-10 修回日期: 2026-02-03)