

引用本文: 农鑫, 卿国能, 朱康奇, 等. 基于 LR-ODCNN 的物联网设备射频指纹信号识别方法[J]. 光通信技术, 2024, 48(3): 68–73.

基于 LR-ODCNN 的物联网设备射频指纹信号识别方法

农鑫¹, 卿国能¹, 朱康奇², 张振荣^{1*}, 郑嘉利¹

(1. 广西大学 计算机与电子信息学院, 南宁 530004; 2. 清华大学 电子工程系, 北京 100084)

摘要: 为了解决物联网环境下设备众多且终端资源有限带来的安全问题, 提出了一种基于轻量级全维动态卷积神经网络(LR-ODCNN)的物联网设备射频指纹信号识别方法。首先, 设计了 LR-ODCNN 模型; 然后, 利用光传输系统采集设备的基带信号, 从基带信号中提取 I、Q 信号作为网络的输入; 最后, LR-ODCNN 模型根据多维注意力机制来适应不同设备的信号特征, 并进行信号特征的提取和识别。实验结果表明, 当传输距离为 10 m、400 m、1.7 km 和 8.6 km 时, LR-ODCNN 模型的平均识别准确率为 94.35%, 比 McAFF 模型、Oracle 模型分别提高了 5.35%、10.13%, 且具有鲁棒性强、轻量化的优点。

关键词: 物联网安全; 设备识别; 全维动态卷积; 射频指纹识别; 深度学习

中图分类号: TN975 **文献标志码:** A **文章编号:** 1002-5561(2024)03-0068-06

DOI: 10.13921/j.cnki.issn1002-5561.2024.03.012

开放科学(资源服务)标识码(OSID):



Radio frequency fingerprint signal recognition method for internet of things devices based on LR-ODCNN

NONG Xin¹, QING Guoneng¹, ZHU Kangqi², ZHANG Zhenrong^{1*}, ZHENG Jiali¹

(1. School of Computer, Electronic and Information, Guangxi University, Nanning 530004, China;

2. Department of Electronic Engineering, Tsinghua University, Beijing 100084, China)

Abstract: In order to address the security problem arising from the numerous devices and limited terminal resources in the internet of things (IoT) environment, a method for radio frequency (RF) fingerprint signal recognition of IoT devices based on lightweight omni-dimensional dynamic convolutional neural network (LR-ODCNN) is proposed. Firstly, the LR-ODCNN model is designed. Then, the baseband signals of the devices are collected using an optical transmission system, and the I and Q signals are extracted from the baseband signals as the input to the network. Finally, the LR-ODCNN model adapts to the signal characteristics of different devices based on a multi-dimensional attention mechanism and performs signal feature extraction and recognition. The experimental results show that the average recognition accuracy of the LR-ODCNN model is 94.35% at transmission distances of 10 m, 400 m, 1.7 km, and 8.6 km, which is an improvement of 5.35% and 10.13% compared to the McAFF model and the Oracle model respectively. Additionally, it boasts strong robustness and lightweight.

Key words: internet of things security, device identification, omni-dimensional dynamic convolution, radio frequency fingerprint recognition, deep learning

0 引言

第五代移动通信(5G)无线系统具有支持每平方

收稿日期: 2024-01-29。

基金项目: 广西重点研发计划项目(桂科 AB22080048)资助。

作者简介: 农鑫(1999—), 男, 广西天等人, 硕士研究生, 现就读于广西大学计算机与电子信息学院电子与通信工程专业, 主要从事于无线通信信号处理中的算法优化、物联网安全和射频指纹识别技术的研究工作。

* 通信作者: 张振荣(1976—), 男, 博士, 教授, 现就职于广西大学计算机与电子信息学院, 主要研究方向为通信网络及光纤传感技术。



千米高达一百万个物联网设备的能力^[1]。为了保证大规模物联网设备的安全运行, 必须对接入网络的设备进行身份识别^[2]。在物联网环境中, 由于设备数量庞大且终端资源有限, 传统的高层识别机制面临前所未有的挑战^[3]。而基于物理层的射频指纹(RFF)识别方法能够在无需密钥分发的情况下实现设备识别^[4], 从而有效规避终端资源限制的问题。

RFF 识别方法主要分为两大类: 一类是基于特征工程的方法, 另一类是基于深度学习的方法。在特征工程方法中, 研究者们依赖于采用经典的信号处理技

术(如傅里叶变换、小波变换等)提取信号的特征。这些特征被用于支持向量机(SVM)算法中进行分类^[5-7]。尽管这种方法在性能上表现出色,但它高度依赖于先验知识,因此在通用性方面存在一定的限制。

随着深度学习技术的兴起,研究者们开始尝试采用该技术进行 RFF 识别。2018 年, WU Q 等人^[8]利用长短期记忆(LSTM)网络成功地提取了信号的时间特征,并展示了出色的识别性能;同年, DING L 等人^[9]则构建了一种轻量级的卷积神经网络(CNN)来提取信号特征,不仅降低了数据的维度,还减少了处理时间。2019 年, SANKHE K 等人^[10]结合了软件定义无线电和机器学习技术,开发出了 Oracle 算法,该算法能够在静态信道中有效地识别设备信号。这些深度学习的方法不仅减少了对先验知识的依赖,还展现出了卓越的自适应学习能力。然而,在复杂的电磁环境中,物联网设备的识别方法面临高计算量和训练收敛速度慢的挑战,这在一定程度上限制了设备接入网络的速度。

为了克服以上技术的局限性,本文提出一种基于轻量级全维动态卷积神经网络(LR-ODCNN)的物联网设备 RFF 信号识别方法,以提高接入设备的识别准确率。

1 LR-ODCNN 模型

本文对 Oracle 算法的 CNN 结构进行改进,设计了一个 LR-ODCNN 模型,如图 1 所示。LR-ODCNN 模型的主要功能涵盖:信号的输入处理,I、Q 信号相关特征的提取,多层时域特征的深入提取,全连接层的特征融合以及最终的输出结果。数据以 $2 \times N$ 的矩阵形式进行表示,其中“ N ”代表时间序列的长度。这种矩阵表示方式有助于减少信号转换过程中所需的计算量和参数量,从而提高网络识别效率,非常符合物联网识别场景中对实时性要求高的特点。该模型在卷积层中采用全维动态卷积,其核心设计思想是借助全维动态卷积来强化 I、Q 信号的特征提取能力。同时,模型中融入了残差模块,以防止梯度消失。此外,采用最大池化层来降低数据维度,最终通过仅包含少量神经元的 2 个全连接层来完成识别任务。

1.1 全维动态卷积层

在全维动态卷积过程中,本文引入一系列注意力向量来优化参数分配,其计算过程如式(1)所示。

$$y = \sum_{i=1}^n (\alpha_i \odot \alpha_{fi} \odot \alpha_{ci} \odot \alpha_{si} \odot W_i) * x \quad (1)$$

其中, y 表示输出特征, x 表示输入特征, n 为卷积核的总数, α_i 表示第 i 个卷积核的注意力标量; α_{fi} 表示第 i 个卷积在输出通道维度上的注意力向量, f 为输出通道维度; α_{ci} 表示第 i 个卷积核在输入通道维度上的注意力向量, c 为输入通道维度; α_{si} 表示第 i 个卷积核在时间维度上的注意力矩阵, s 为时间维度; W_i 表示第 i 个卷积核, $\odot$ 表示不同维度的乘法操作(元素对应相乘), $*$ 表示卷积操作。

全维动态卷积层通过注意力机制对多个卷积核进行加权线性组合,为处理复杂的原始 I、Q 信号特征提供了灵活的网络结构,并能够根据不同设备信号的特点动态调整卷积核的尺寸和形状,从而精准适应信号特征。此外,在全维动态卷积层结构的全连接层中,本文采用了多种激活函数,包括 Softmax、Sigmoid 和 ReLU 等,以增强网络的非线性映射能力和分类准确性。

在神经网络的训练阶段,全维动态卷积层将自动学习原始 I、Q 信号的特征。这一过程首先会将输入特征转化为低维空间,然后利用 4 个不同维度的注意力机制,计算出各个维度的注意力权重。这些权重随后与卷积核相乘,从而实现卷积核权重的动态调整,通过卷积操作将处理后的结果与输入特征结合,形成自适应的动态卷积,有效提取不同信号的关键特征信息。全维动态卷积通过 4 个维度的注意力加权对核空间进行处理,以非线性方式叠加卷积核,它综合考虑卷积核空间、输入和输出通道信息,充分捕获上下文信息。最终,全维动态卷积层成功提取了更具代表性的信号特征,为提高网络模型的识别能力奠定了坚实基础。

1.2 残差模块结构

随着深度学习在多个领域的突破性应用,神经网络的深度与其性能之间的关系成为了研究的热点。然而,网络的加深往往伴随着训练难度的增加,尤其是梯




图 1 LR-ODCNN 模型结构

农鑫,卿国能,朱康奇,等:基于 LR-ODCNN 的物联网设备射频指纹信号识别方法

度消失和梯度爆炸问题。深度残差网络(ResNet)^[11-13]的设计有效地解决了这些问题,其核心思想是在输入和输出通道之间构建相互连接的路径,采用一种被称为“shortcut connection”的连接方式^[14-15]。这种设计允许输入信息直接传递到输出层,从而避免了信息的丢失。在训练网络时,研究人员只需利用这些直接传递的残差信息来优化训练过程。ResNet 结构原理示意图如图 2 所示。




图2 ResNet 结构原理示意图

残差模块输出公式可以表示为

$$H(x)=F(x)+x \quad (2)$$

其中, $H(x)$ 表示输出, $F(x)$ 表示残差。

残差是指在模型准确率已达较高水平时,学习焦点会转向恒等映射的学习。在这种情况下,ResNet 会调整其学习目标,不再致力于学习完整的输出结果,而是专注于捕捉输入 x 与目标输出 $H(x)$ 之间的差异。

本文对 ResNet 结构进行了改进,即在 ResNet 结构中引入了全维动态卷积思想,改进后的残差模块结构如图 3 所示。全维动态卷积层通过整合 4 种不同的注意力机制,增强了卷积层的表达能力,并结合批量归一化提升了模型的泛化能力,加速了收敛过程。在残差模块中运用全维动态卷积,有助于网络更精准地学习输入与输出之间的差异。其提供的动态调整机制使得卷积层能够更灵活地适应多样化的输入特征,从而提升了学习效率和特征提取的质量。

2 RFF 信号识别方法

基于 LR-ODCNN 的物联网设备 RFF 信号识别方法流程如图 4 所示,该流程主要包含离线训练和在线测试两大步骤。在初始阶段,首先对基带信号进行预处理,以适应神经网络的输入要求。随后,这些预处理后




图3 本文提出的残差模块结构




图4 基于 LR-ODCNN 的物联网设备 RFF 信号识别方法流程

的信号被送入 LR-ODCNN 模型进行训练。在训练过程中,模型致力于深度挖掘信号中的核心特征。凭借这些特征,模型能够精准地识别并区分不同的身份类型,并为各身份类型确立明确的特征标准。紧接着,基于已成功识别的身份类型,进一步构建设备识别模型,该模型具备将新出现的未知设备信号准确归类到对应身份类型的能力。进入在线测试阶段后,该模型比较输入的

未知设备信号与已存储的设备特征,从而精准判断设备的类型,最终完成 RFF 信号的精确识别。

2.1 数据预处理

为了适应神经网络结构的输入要求,需要处理具有不同长度的传输信号,将其转换为等长的信号样本。本文采取一种随机移动窗口的方法来切片处理基带信号的 I、Q 数据。具体来说,每个设备基带信号的 I、Q 数据可以表示为一个矩阵 S_i ,其中的 I、Q 分量分别对应于不同的时间点。

$$S_i = \begin{bmatrix} A_1 & A_2 & \cdots & A_{M_i} \\ B_1 & B_2 & \cdots & B_{M_i} \end{bmatrix} \quad (3)$$

其中, A 、 B 分别表示基带信号中的 I、Q 数据, M_i 表示第 i 个传输信号中包含的采样点的总数。

随机移动的窗口大小设定为 s , 窗口滑动的步长 v_k 是从均匀分布 $U(1, s/10)$ 中随机采样得到的, 这种随机性导致了切片之间的重叠程度各不相同, 从而增加了样本的多样性。假设数据进行切片后得到的第 k 个序列样本可以表示为

$$x_k = \begin{bmatrix} A & A & \cdots & A \\ 1+\sum_{j=0}^k v_j & 2+\sum_{j=0}^k v_j & \cdots & s+\sum_{j=0}^k v_j \\ B & B & \cdots & B \\ 1+\sum_{j=0}^k v_j & 2+\sum_{j=0}^k v_j & \cdots & s+\sum_{j=0}^k v_j \end{bmatrix} \quad (4)$$

在切片过程中, 本文定义了序列索引的范围 $k=0, 1, 2, \dots, Z$, 其中 Z 是满足不等式 $s + \sum_{j=0}^k v_j \leq M_i$ 的最大整数。这样定义确保了最后一个序列的末端不会超过原始传输信号的长度。同时, 每个切片都保留了信号的标签, 从而保证了数据的一致性和可追溯性。在实验过程中, 每个样本包含 512 个 I 通道采样点和 512 个 Q 通道采样点, 即滑动窗口的大小 $s=512$ 。

接下来, 使用最大-最小规范化方法对数据进行归一化处理, 将数值范围限制在 $[0, 1]$ 之间, 以提高学习效率并加速模型收敛。此外, 本文还为每个样本分配了身份标签, 以便识别不同物联网设备的 RFF 信号。

2.2 LR-ODCNN 模型的建立

经过预处理的 I、Q 信号子序列被输入到 LR-ODCNN 模型中进行训练, 该训练过程主要包括信号特征提取和信号分类 2 个阶段。具体流程如下:

在特征提取阶段, 输入的信号格式为 $2 \times N$ 。首先, 本文使用 $(2, 1)$ 的卷积核来提取 I、Q 信号的相关特征, 并将二维数据转换为一维, 从而减少后续卷积的计算量。接着, 应用 2 个残差模块来深入探索信号的时域结构特征, 同时降低梯度爆炸的风险。随后, 通过

一个卷积核大小和步长均为 $(1, 2)$ 的最大池化层, 进一步降低数据的维度。

在信号分类阶段, 本文利用 2 层全连接层(全连接层之间加入了 50% 的 Dropout 层)作为分类器。经过 Softmax 分类器处理的信号特征将产生一个概率分布。每个类别的预测概率都在 $0 \sim 1$ 之间, 并且所有类别的概率总和为 1。这一过程可以表示为

$$P(y=\beta | x) = \frac{e^{w_\beta^T x}}{\sum_{j=1}^C e^{w_j^T x}} \quad (5)$$

其中, y 表示输出的类别标签, x 表示输入的信号样本; β 表示设备分类的类型, $\beta \in \{0, 1, 2, \dots, C-1\}$, C 表示分类总数; $e^{w_\beta^T x}$ 表示类别 β 的得分, 通过输入 x 与类别 β 对应的权重向量 w_β 的点积(即 $w_\beta^T x$)计算得到的指数; w_j 表示与类别 j 关联的权重向量。

LR-ODCNN 模型使用交叉熵损失函数来衡量模型对数据的拟合程度, 如式(6)所示。损失函数的值越小, 代表模型的识别性能越好。

$$L = \frac{1}{\delta} \sum_{i=0}^{\delta} L_i - \sum_{c=1}^C y_{ic} \lg p_{ic} \quad (6)$$

其中, L 是总损失, p_{ic} 是模型预测样本 i 属于类别 c 的概率; y_{ic} 是一个指示器变量, 如果样本 i 属于类别 c , 则 $y_{ic}=1$, 否则 $y_{ic}=0$ 。

2.3 设备 RFF 信号识别

当物联网设备未经识别就尝试接入网络时, 接入点会捕获其基带信号, 并通过已建立的设备识别模型评估其与已知设备特征的匹配程度。模型将输出一组概率值 $P=\{P_1, P_2, \dots, P_C\}$, 其中每个概率值都对应于模型预测的类别, 数值越高表示属于该类别的可能性越大。

如果所有的 P 均低于阈值 a (该阈值由所有正确预测的平均概率决定), 即 $\max\{P_1, P_2, \dots, P_C\} < a$, 这表明未知设备的 RFF 特征与任何已知设备都不匹配则, 该设备被归类为高风险设备, 因此网络接入点将拒绝其接入。在其它情况下, 本文将基于 $\max\{P_1, P_2, \dots, P_C\}$, 识别对应的设备类型作为未知设备的身份, 从而完成设备的识别过程。

3 实验与结果分析

本文的实验平台基于 Windows 10x64 操作系统, 配备了 Intel Xeon Gold 6142 CPU(主频 2.30 GHz), 并使用了 NVIDIA GeForce RTX 3090-Ti 显卡和 32 GB

衣鑫,卿国能,朱康奇,等:基于 LR-ODCNN 的物联网设备射频指纹信号识别方法

内存。在软件方面,采用了 PyTorch 2.0.1 深度学习框架,并使用 Python 3.10.12 作为编程语言。

3.1 实验流程

3.1.1 数据采集

RFF 信号采集流程如图 5 所示。本文使用嵌入 NRF24LE1 芯片的 6 个射频器件,生成载波频率、带宽分别为 2.42 GHz、1 MHz 的信号来模拟物联网设备的信号。首先,通过马赫-曾德尔调制器对波长为 1 550 nm 的光信号进行调制,调制后的信号在 10 m、400 m、1.7 km 和 8.6 km 共 4 种不同长度的单模光纤中传输,并利用掺铒光纤放大器放大信号功率。然后,通过光电探测器将光信号转换为电信号,并将信号送入混频器与 2.419 GHz 的本地振荡器进行信号混合。再通过低通滤波器滤除高频成分,实现信号的降频。最后,使用采样率为 20 MSa/s 的示波器记录信号,采集 I、Q 信号样本。




图 5 RFF 信号采集流程图

实验将采集的 12 000 个 I、Q 信号样本(每个设备采集 2 000 个样本,共 6 个设备)按 8:2 的比例随机划分为训练集和测试集,用于神经网络的训练。

3.1.2 实验结果

LR-ODCNN 模型的全层参数初始化如表 1 所示。其中,全维动态卷积层参数通过实验优化获得,最大池化层的设置依据全维动态卷积层的输出而定。

表 1 LR-ODCNN 模型的全层参数

参数	值
全维动态卷积层 1 卷积核/个	64
全维动态卷积层 1 尺寸	2×1
残差模块全维动态卷积层 1 卷积核/个	64
残差模块全维动态卷积层 1 尺寸	1×7
残差模块全维动态卷积层 2 卷积核/个	64
残差模块全维动态卷积层 2 尺寸	1×7
最大池化层窗口尺寸	1×2
全连接层 1 神经元/个	32
全连接层 2 神经元/个	6
dropout 率/%	50

LR-ODCNN 模型在不同传输距离条件下的训练次数与识别准确率的关系如图 6 所示。可以看出,随着训练次数的不断增加,设备的识别准确率得到了显著的提升。当模型完成了 100 次训练后,无论传输距离如何变化,设备识别的准确率均稳定地保持在 93% 以上。这充分证明了 LR-ODCNN 模型在不同传输距离环境下都能实现高效且稳定的物联网设备的识别。




图 6 不同传输距离下,识别准确率与训练次数关系

3.2 实验对比与分析

实验首先评估了在不同条件下 McAFF^[19] 模型、Oracle 模型以及 LR-ODCNN 模型的识别效果,然后通过对分析这些模型的表现,进一步验证了 LR-ODCNN 模型的识别能力。

3.2.1 识别准确率比较

为了更清晰地呈现 3 种模型在不同传输距离下的性能表现,本文选取了传输距离为 10 m、400 m、1.7 km 和 8.6 km 的数据集对 LR-ODCNN、McAFF 和 Oracle 模型进行了训练,实验结果如表 2 所示。根据表 2 计算可知,LR-ODCNN 模型、McAFF 模型和 Oracle 模型的平均识别率分别为 94.35%、88.75% 和 84.45%。同时,从表 2 可以看出,随着传输距离的增加,LR-ODCNN 模型的识别准确率仍能保持在较高水平,识别效果明显优于 McAFF 和 Oracle 模型。

3.2.2 性能测试

本文针对传输距离为 400 m 的数据集添加了不

表 2 不同传输距离对模型识别准确率的影响

传输距离	不同模型的识别准确率/%		
	LR-ODCNN	McAFF	Oracle
10 m	95.3	90.7	85.3
400 m	94.6	89.4	84.9
1.7 km	94.1	88.3	84.1
8.6 km	93.4	87.6	82.6

同强度的高斯白噪声,以模拟有噪信道的环境,并观察识别准确率随信噪比(SNR)的变化情况,实验结果如图7所示。可以看出,在低 SNR 条件(如-10~0 dB)下,所有模型的性能均受到显著影响;随着 SNR 的提高,所有模型的识别准确率均有所提升;在 20 dB 的高 SNR 条件下,McAFF 模型和 Oracle 模型的识别准确率分别为 90%和 85%,LR-ODCNN 模型的识别准确率进一步提升至95%,比 McAFF 模型和 Oracle 模型分别提升了5%和10%。这表明本文所提出的算法模型在处理高斯白噪声的干扰时具有更强的鲁棒性。




图7 不同信噪比对识别准确率的影响

3种模型的训练参数量和浮点运算次数(FLOPs)的比较情况如表3所示。可以看出,LR-ODCNN 模型的训练参数量和 FLOPs 均较少,因此计算复杂度相对较低。这主要得益于全维动态卷积层在提高模型性能的同时,未引入额外的训练参数或增加计算复杂度。

表3 网络模型参数比较情况

模型	参数量	FLOPs
LR-ODCNN	$0.480\ 18\times 10^6$	12.96×10^6
McAFF	6.98×10^6	96.78×10^6
Oracle	$0.168\ 16\times 10^6$	20.25×10^6

4 结束语

本文提出了一种基于 LR-ODCNN 的物联网设备射频指纹信号识别方法,将全维动态卷积应用于 RFF 信号识别场景,构建了 LR-ODCNN 模型,提高了物联网设备接入网络前的物理层安全性。这种方法解决了传统加密方法所面临的复杂性和资源消耗问题,从而在本质上提高了物联网的安全性。实验结果表明,在同等实验条件下,相较于其它传统 CNN 模型,LR-ODCNN 模型展现出更高的识别准确率和鲁棒性。此外,该模型还具有较少的训练参数量和 FLOPs,为物联网设备识别的实际部署提供了有益的参考。

参考文献:

- [1] OSSEIRAN A, PERSSON P, ZAIDIET A, et al. Ericsson white paper: 5G wireless access: an overview[R/OL]. [2024-01-29]. <https://www.ericsson.com/en/reports-and-papers/white-papers/5g-wireless-access-an-overview>.
- [2] KHAN A A, LAGHARI A A, SHAIKH Z A, et al. Internet of things (IoT) security with blockchain technology: a state-of-the-art review [J]. IEEE Access, 2022, 10: 122679-122695.
- [3] LAWU B L, FILBERT F, ASIH K, et al. A systematic literature review of internet of things cybersecurity [C]//AIP. Proceedings of the 3rd International Conference on Robotic Automation and Biomimetic Harmonic Advanced Research (ICOBAR) 2021. Melville: AIP Publishing, 2023: 203-207.
- [4] ZHANG J, WOODS R, SANDELL M, et al. Radio frequency fingerprint identification for narrowband systems, modelling and classification [J]. IEEE Transactions on Information Forensics and Security, 2021, 16: 3974-3987.
- [5] ZHANG J, SHEN G, SAAD W, et al. Radio frequency fingerprint identification for device authentication in the internet of things [J]. IEEE Communications Magazine, 2023, 61(10): 110-115.
- [6] YANG Y, YAN T. RF fingerprint recognition method based on DBN-SVM [C]//IEEE. Proceedings of 2022 IEEE 10th International Conference on Information, Communication and Networks (ICICN). Zhangye: IEEE, 2022: 572-577.
- [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, 2022, 12(1): 214-234.
- [8] WU Q, FERES C, KUZMENKO D, et al. Deep learning based RF fingerprinting for device identification and wireless security [J]. Electronics Letters, 2018, 54(24): 1405-1407.
- [9] DING L, WANG S, WANG F, et al. Specific emitter identification via convolutional neural networks [J]. IEEE Communications Letters, 2018, 22(12): 2591-2594.
- [10] SANKHE K, BELGIOVINE M, ZHOU F, et al. ORACLE: optimized radio classification through convolutional neural networks [C]//IEEE. Proceedings of INFOCOM 2019-IEEE Conference on Computer Communications. Paris: IEEE, 2019: 370-378.
- [11] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution[J]. arXiv preprint, 2022, 14(8): 2209-2216.
- [12] PAN Y, YANG S, PENG H, et al. Specific emitter identification based on deep residual networks[J]. IEEE Access, 2019, 7: 54425-54434.
- [13] 杨小伟,王泽跃,杨鹤猛,等. 基于残差神经网络的无人机射频信号识别[J]. 电讯技术, 2023, 63(1): 101-106.
- [14] FANG W, YU Z, CHEN Y, et al. Deep residual learning in spiking neural networks [J]. Advances in Neural Information Processing Systems, 2021, 34: 21056-21069.
- [15] JIAN T, RENDON B, OJUBA E, et al. Deep learning for RF fingerprinting: a massive experimental study [J]. IEEE Internet of Things Magazine, 2020, 3(1): 50-57.
- [16] ZENG Y, GONG Y, LIU J W, et al. Multi-channel attentive feature fusion for radio frequency fingerprinting[EB/OL]. [2024-01-29]. <https://arxiv.org/pdf/2303.10691v2>.