

引用本文: 赵建鼎, 李靖超, 赵静, 等. 基于梳状滤波的改进 CNN-GRU 射频信号“基因”分类识别方法[J]. 光通信技术, 2025, 49(3): 59-66.

基于梳状滤波的改进 CNN-GRU 射频信号“基因”分类识别方法

赵建鼎¹, 李靖超^{1*}, 赵静¹, 应雨龙², 张斌³

(1. 上海电机学院 电子信息学院, 上海 201306; 2. 上海电力大学 能源与机械工程学院, 上海 200090; 3. 日本神奈川大学 工学部, 横滨)

摘要: 针对物联网终端设备射频指纹分类识别率不高的问题, 提出一种基于梳状滤波的改进卷积神经网络-门控循环单元 (CNN-GRU) 射频信号“基因”分类识别方法。首先, 通过梳状滤波器增强射频信号的时频特征, 构建具有设备唯一性的“基因图谱”; 其次, 将传统一维 CNN 扩展为三层二维结构, 结合双层 GRU 实现时-频联合特征提取与序列建模; 最后, 引入混合池化与指数线性单位 (ELU) 激活函数优化特征表达能力。实验结果表明: 该方法在仿真数据中识别准确率达 100%, 实测数据达 95.52%, 较传统算法提升 5%~22%, 显著提高了物联网设备的安全性和管理效率。

关键词: 无线通信设备识别; 射频信号“基因”; 梳状滤波; 深度学习; 基因图谱

中图分类号: TN929.5 **文献标志码:** A **文章编号:** 1002-5561(2025)03-0059-08

DOI: 10.13921/j.cnki.issn1002-5561.2025.03.010

开放科学 (资源服务) 标识码 (OSID):



Comb filter-based improved CNN-GRU radio frequency signal "gene" classification and recognition method

ZHAO Jianding¹, LI Jingchao^{1*}, ZHAO Jing¹, YING Yulong², ZHANG Bin³

(1. School of Electronic and Information Engineering, Shanghai DianJi University, Shanghai 201306, China;

2. College of Energy and Mechanical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

3. Department of Mechanic Engineering Kanagawa University, Yokohama, Japan)

Abstract: To address the low classification and recognition rate of radio frequency fingerprints in internet of things (IoT) terminal devices, this paper proposes an improved convolutional neural network-gated recurrent unit (CNN-GRU) method based on comb filtering for radio frequency signal "gene" classification and recognition. First, the time-frequency characteristics of RF signals are enhanced using a comb filter to construct a unique "gene map" for each device. Second, the traditional one-dimensional CNN is expanded into a three-layer two-dimensional structure, combined with a dual-layer GRU to achieve joint time-frequency feature extraction and sequence modeling. Finally, hybrid pooling and exponential linear unit (ELU) activation functions are introduced to optimize feature representation. Experimental results show that the proposed method achieves a identification accuracy of 100% in simulated data and 95.52% in real-world data, outperforming traditional algorithms by 5%-22%, significantly enhancing the security and manage-ment efficiency of IoT devices.

Key words: wireless communication device identification, radio frequency signal "gene", comb filtering, deep learning, gene map

收稿日期: 2024-09-14。

基金项目: 国家自然科学基金面上基金项目 (62076160) 资助; 上海市“曙光计划”项目 (23SG55) 资助; 上海市青年科技启明星项目 (23QA1-40380) 资助; 上海市重型燃气轮机领域联合创新计划 (UIC 计划) 项目 (GYQJ-2023-1-06) 资助。

作者简介: 赵建鼎 (1999—), 男, 硕士研究生, 主要研究方向为物联网物理层认证, 参与了国家自然科学基金面上项目, 以及多项校级科研项目。曾荣获第十九届中国研究生电子设计竞赛团队三等奖、中国国际大学生创新大赛 (2024) 上海赛区优胜奖。

*** 通信作者:** 李靖超 (1986—), 女, 教授, 博士, 硕士生导师, 主要研究方向为信号处理、物联网物理层认证、故障诊断等。



0 引言

第六代移动通信 (6G) 技术和物联网设备的普及使无线通信在军事和民用领域变得至关重要。然而, 开放的无线网络环境使传输的信息容易受到安全威胁^[1-2]。传统方法依赖协议认证和密码加密, 但密钥泄露可能导致认证环节被攻破, 进而破坏通信网络。因此, 物联网终端亟需一种新的安全机制, 以加强身份验证并降低恶意用户的威胁风险。

在现有的技术中, 物联网终端无线通信设备的分类识别方法主要有 3 种:

1) 基于特征工程的方法。例如, 文献[3]提出一种

赵建鼎,李靖超,赵静,等.基于梳状滤波的改进 CNN-GRU 射频信号“基因”分类识别方法

基于数据包长度分布的实用物联网设备识别系统,采用 K 值邻近法作为分类器,其分类识别结果具有较好的拓展性和适应性。文献[4-5]利用多节点估计的信道矩阵作为认证输入,通过下采样控制矩阵维度以提升识别准确率。文献[6]则提出一种基于物理层前导码中提取的多种多域特征进行分类识别的方法,在 15 类 Wi-Fi 设备中识别准确率高达 98%,即便在具有相同类型网卡的设备中也能达到 90.76%。

2)基于统计建模的方法。例如,文献[7]提出一种基于高斯分布理论的设备识别算法,当信噪比(SNR)大于 15 dB 时,平均识别准确率超过 92%。文献[8]则在支持向量数据描述(SVDD)算法的基础上提出了一种通信设备射频指纹认证模型,能够对移动物联网通信设备进行分类识别,当 SNR 为 15 dB 时,该模型的认证成功率达到 90%。

3)基于深度学习的方法。例如,文献[9]提出一种基于差分轮廓恒星的物联网物理层认证方法,对同一厂家、同一类型、同一批次的 20 个 Wi-Fi 网卡设备的识别认证测试准确率可达 98.6%。文献[10]提出一种基于差分复值卷积神经网络(CNN)的通信辐射源个体识别方法,有效减少所采集的稳态数据传输段所需的数据长度,总体识别率达到 99.7%。文献[11]则设计了轻量级全维动态卷积神经网络(LR-ODCNN),其模型的平均识别准确率为 94.36%。随着硬件工艺的进步,物联网终端无线通信设备的射频器件容差逐渐缩小,使得射频指纹的提取与分类识别更加困难^[12-13]。文献[14-15]借鉴生物基因概念,利用分形理论和灰色关联算法对射频信号进行识别,准确率可达 98.2%。近年来,深度学习逐渐取代人工特征提取^[16-17],提高了分类识别^[17-18]的便捷性和适用性^[19-20]。

尽管现有方法在特定场景下取得了一定成效,但仍存在诸多局限。例如,特征工程方法依赖人工设计,泛化能力较弱;统计建模方法对信道条件敏感,识别稳定性不足;而现有深度学习方法多聚焦于一维时域特征,难以充分挖掘射频信号的多维结构信息,且对同类设备的微差识别能力仍有限。为此,本文提出一种基于梳状滤波的改进卷积神经网络-门控循环单元

(CNN-GRU)射频信号“基因”(下文简称射频信号基因,指从设备射频信号中提取的、具有区分度的频域/时频域特征,用于设备身份识别)分类识别方法,旨在通过构建信号“基因图谱”并融合二维卷积与时序建模,提高对物联网终端设备间细微差异的识别能力与鲁棒性。

1 射频信号基因分类识别方法

本文提出一种基于梳状滤波的改进 CNN-GRU 射频信号基因分类识别方法。首先,通过梳状滤波器在固定位置对设备信号进行频率增益,放大并提取射频信号基因特征;然后,结合多层二维 CNN 和 GRU 进行特征提取与分类。

1.1 改进的 CNN-GRU 模型

本文提出的改进 CNN-GRU 模型架构如图 1 所示。该模型主要包含以下 3 项核心优化:

1)卷积模块的维度 d 扩展:将单层一维卷积扩展为三层二维卷积结构,卷积核尺寸依次递减(500×500、100×100、10×10),对应过滤器数量分别为 128、64 和 64。这种多尺度层级设计可有效提取射频信号基因图谱中的时频联合特征。

2)时序建模能力增强:采用双层 GRU 结构替代单层设计,隐藏单元数分别为 64 和 32,显著提升了时序特征的捕获能力。

3)特征分辨率保持:所有卷积层均采用单位池化窗口,避免特征信息损失。

上述改进使模型对复杂时频模式的表征能力得到显著提升。二维卷积结构可直接建模信号在时域和频域的局部相关性,而深层网络架构结合优化后的激活函数,进一步增强了特征提取的精度与模型鲁棒性。

在特征提取机制方面,CNN 通过卷积层捕获空间局部特征,并利用池化层实现特征降维;GRU 则通过更新门与重置门机制,有效管理序列数据的长期依赖关系。本模型首先通过 CNN 提取输入数据的空间特征,再将特征序列输入 GRU 进行时序建模。这种混合架构兼具空间特征提取和时序关系建模的优势,既能避免传统循环神经网络(RNN)的梯度消失问题,又适




图 1 改进的 CNN-GRU 模型

用于处理射频信号等具有时空关联特性的数据。实验研究表明,该模型在时频特征联合分析任务中具有卓越性能。

GRU 的内部结构如图 2 所示。图中, $h_{(t-1)}$ 为上一个时间步隐藏状态的输出向量, x_t 为当前时间步的输入向量, z_t 与 r_t 分别为更新门与重置门。

在 t 时刻, 更新门 z_t 与输入数据的关系可表达为

$$z_t = \sigma(w^{(z)} x_t + u^{(z)} h_{(t-1)}) \quad (1)$$

其中, $w^{(z)}$ 与 $u^{(z)}$ 分别代表更新门中 x_t 和 $h_{(t-1)}$ 的权重矩阵; σ 表示激活函数 sigmoid, 用于对输入信号 (即当前时刻的线性变换 x_t 和 $h_{(t-1)}$ 之和) 进行非线性映射, 其值为 0~1。

更新门通过对当前时刻的输入信息 x_t 与上一时刻输出的信息 $h_{(t-1)}$ 进行加权, 从而决定要传递过去多少信息, 帮助模型减少梯度消失的风险。

重置门的作用与更新门不同, 它决定要遗忘多少过去的信息, 其表达式为

$$r_t = \sigma(W^{(r)} x_t + U^{(r)} h_{(t-1)}) \quad (2)$$

其中, $W^{(r)}$ 与 $U^{(r)}$ 分别代表重置门中的 x_t 和 $h_{(t-1)}$ 的权重矩阵, 其余参数与更新门含义相同。重置门 r_t 的最终结果为 0~1。

在 GRU 结构中, 过去的信息会通过重置门进行储存, 并结合当前时间步输入的信息决定当前的记忆内容 $\tilde{h}_t$, 计算公式如下:

$$\tilde{h}_t = \tanh(w^{(h)} x_t + r_t \odot U^{(h)} h_{(t-1)}) \quad (3)$$

其中, $w^{(h)}$ 与 $U^{(h)}$ 分别代表当前记忆内容中 x_t 和 r_t 的权重矩阵, 其余参数含义不变。式(3)中重置门结果与过去的信息 $h_{(t-1)}$ 经过线性变换后进行哈达玛乘积, 用于控制过去信息的遗忘速度。

最终更新门将和当前的记忆内容共同作用, 决定当前时间步的最终输出信息 h_t , 其计算表达式如下:

$$h_t = z_t \odot h_{(t-1)} + (1 - z_t) \odot \tilde{h}_t \quad (4)$$

由式(4)可知, 最终输出信息 h_t 通过更新门 z_t 来决定保留多少当前记忆信息与过去的信息。而当前时刻 GRU 单元中的最终输出信息 h_t 将作为下一时刻单




图 2 GRU 的内部结构

元的输入, 通过传递过去的记忆信息帮助网络进行学习。

在实际应用中, 由于 GRU 需要的参数较少, 它不仅更容易收敛, 而且运算速度更快。此外, GRU 还能有效避免过拟合问题, 在数据集有限的情况下表现出优异的性能。

1.2 方法实现

本文提出的基于梳状滤波的改进 CNN-GRU 射频信号基因特征分类识别方法的具体实现步骤为射频信号预处理与基因提取和基因图谱构建与可视化表示。

1.2.1 射频信号预处理与基因提取

在预处理阶段, 首先对原始 I/Q 双路信号应用梳状滤波器进行频率选择性增强, 这有助于提取出射频信号的基因, 进而构建基因图谱。其计算表达式为

$$Y[n] = X[n] + \alpha X[n-M] \quad (5)$$

其中, $Y[n]$ 是输出信号, $X[n]$ 是输入信号, M 是滤波器的延迟参数, 该参数决定频率响应中峰值或零点的间隔。 α 是前反馈稀疏, 控制梳状效果的强度。

在频率域中, 梳状滤波器的增益函数可以通过对上述差分方程进行 Z 变换得到。其频率响应表示为

$$H(e^{j\omega}) = 1 + \beta e^{-j\omega m} \quad (6)$$

其中, β 是标准化频率, 可以通过改变参数 β 和 m , 调整滤波器的频率响应, 在信号的特定位置上进行增益或衰减, ω 是频率变量; m 是控制时间间隔。

混频器的输出信号 $z(t)$ 经梳状滤波器进行频域特征增强, 因此频率增益是很重要的通信设备射频信号基因产生因素, 频率增益的输出为

$$w(t) = h_{PA}(z(t) \tilde{a}_{ix}) \otimes H_{BP}(f) \quad (7)$$

其中, $h_{PA}(\tilde{a}_{ix})$ 为频率增益的非线性函数, $\tilde{a}_{ix}$ 为幂级数;

$H_{BP}(f)$ 为梳状滤波器的滤波器函数, $H_{BP}(f) = \begin{cases} 1, & |f| < w_c \\ 0, & |f| > w_c \end{cases}$, f 为频率变量、 w_c 为滤波器的截止频率。

1.2.2 基因图谱构建与可视化表示

经过频率增益处理后得到的射频信号基因, 可以通过皮尔逊相关系数计算基因信息之间的相关性。皮尔逊相关系数计算公式如下:

$$r = \frac{\sum_{i=1}^R (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^R (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^R (y_i - \bar{y})^2}} \quad (8)$$

其中, x_i 和 y_i 是一对观测值, $\bar{x}$ 和 $\bar{y}$ 分别是 x 和 y 的平

赵建鼎,李靖超,赵静,等.基于梳状滤波的改进 CNN-GRU 射频信号“基因”分类识别方法

均值, R 是观测指数, n 是观测值的数量。

然后,通过散点图(scatter plot)的方式将射频信号基因可视化,并采用 Voronoi 图基于点密度上色的方法对基因图谱进行分区。每个分区包含一个数据点,且分区内的任何位置到该数据点的距离都比到其它任何数据点更近。每个 Voronoi 单元的数据密度是该单元内点的数量除以单元的面积,其密度计算公式为

$$D_{\text{vor}} = \frac{N_{\text{point}}}{A_{\text{cell}}} \quad (9)$$

其中, D_{vor} 为 Voronoi 单元的数据点密度, N_{point} 为该 Voronoi 单元包含的数据点数量, A_{cell} 为该 Voronoi 单元的面积。该公式用于度量每个 Voronoi 单位内的数据分布密度,密度值越高,表明该区域内数据点越集中,有助于对基因图谱的特征区域进行有效划分与表示。

接下来,应用一个二维滑动平均滤波器对数据密度进行平滑处理。通过计算各点的数据密度,并根据这些密度值来决定每个点的颜色。颜色的强度直接反映了对应位置数据密度的高低。

射频信号基因图谱特征融合的方式与流程如图 3 所示。在整体处理流程中,首先采集多个 ESP8266 无线通信模块的 I/Q 双路射频信号,利用梳状滤波器对信号进行频率增益处理,从而增强其反映设备差异的核心特征。随后,通过皮尔逊相关系数计算不同基因特征之间的相关性,将处理结果以散点图形式可视化,构建初步的射频信号基因图谱。在密度着色方法流程中,通过 Voronoi 图对图谱空间进行区域划分,并对各

Voronoi 单元内的数据点数量进行统计,计算其密度值,采用颜色梯度映射将密度信息可视化,从而提升图谱的结构清晰度与特征分辨能力。

1.2.3 特征提取与分类建模

为适应该二维图谱结构,本文将原有的一维 CNN 特征提取层拓展为三层二维结构,分别引入最大池化与平均池化操作,以提取图谱的全局与方向性特征;同时采用指数线性单元(ELU)作为激活函数,进一步提升模型的非线性表达能力与训练收敛速度。二维 CNN 的计算表达式为

$$y_{(i,j)}^{\text{conv}} = \sum_{a=0}^{p-1} \sum_{b=0}^{q-1} x_{(i+a,j+b)} k_{(a,b)} \quad (10)$$

其中, a 是基因图谱的横轴, b 是基因图谱的纵轴, k 是 $p \times q$ 的卷积核, p 和 q 是池化窗口的高度和宽度, $y_{(i,j)}$ 是输出横轴和纵轴在位置 (i,j) 的值, $x_{(i+a,j+b)}$ 是输入基因图谱的横轴和纵轴在位置 $(i+a,j+b)$ 的值, $k_{(a,b)}$ 是卷积核在位置 (a,b) 的值。

二维最大池化层的计算表达式为

$$y_{(i,j)}^{\text{max}} = \max_{a=0}^{p-1} \max_{b=0}^{q-1} x_{(Si+a,Sj+b)} \quad (11)$$

其中, $x_{(Si+a,Sj+b)}$ 是输入横轴和纵轴在位置 $(Si+a,Sj+b)$ 的值, $\max$ 表示池化操作,在指定窗口中选择最大值, S 是步长(stride)。

二维平均池化层的计算表达式如下:

$$y_{(i,j)}^{\text{avg}} = \frac{1}{p \times q} \sum_{a=0}^{p-1} \sum_{b=0}^{q-1} x_{(is+a,js+b)} \quad (12)$$

其中, $x_{(is+a,js+b)}$ 是输入基因图谱横轴和纵轴在位置 $(is+a,js+b)$ 的值, $\frac{1}{p \times q}$ 表示求平均时的归一化因子。

本文将原有的 1 层 GRU 编码建模层改成了 2 层,对射频信号基因图谱中的信号基因特征进行多信度的特征建模学习,并引入 dropout 层防止编码建模层过深造成模型过拟合。

2 仿真结果与分析

2.1 基于仿真信号的识别结果与分析

为验证系统的有效性,本文使用 4 种仿真的频移键控(FSK)信号(无噪声 FSK 信号、添加白噪声的 FSK 信号、添加瑞利噪声的 FSK 信号以及添加莱斯衰落噪声的 FSK 信号)进行测试。所有




图 3 射频信号基因图谱特征融合的方式与流程

信号统一设置采样频率为 20 000 Hz,比特率为 100 b/s,比特时长为 0.1 s,比特数为 10。其中,白噪声和莱斯噪声 SNR 均为 5 dB,瑞利噪声尺度参数 σ 为 0.5,莱斯噪声 k 因子为 5。


4 种仿真信号波形图如图 4 所示。可以看出,无噪声的 FSK 信号具有清晰、平稳的波形边界,能准确反映频移键控的调制特征;而添加白噪声后的信号波形出现较明显的随机扰动,信号边缘模糊;加入瑞利噪声的信号波动更为剧烈,呈现出衰落信道中的非线性衰减特征;莱斯衰落噪声下的信号则在整体幅值结构上表现出较强的多路径干扰痕迹。这些差异反映了不同噪声模型对信号时域结构的破坏程度各异,为后续射频基

因特征的提取与分类识别提供了仿真验证的基础。


本文将这 4 种不同的仿真信号通过梳状滤波器进行频率增益以提取射频基因,随后实施分类识别,结果表明,4 种仿真信号的识别准确率达到了 100%。该结果不仅展示了模型预测结果与实际情况之间的高度匹配,也充分验证了系统在理想环境下的有效性。

为验证系统对不同调制方式和信号(模拟信号、数字信号)方面的普适性,本文另外使用了相移键控(PSK)信号、FSK 信号、正交幅度调制(QAM)信号和相位调制(PM)信号这 4 种类型的信号进行有效性测试,并对每种信号添加了白噪声以模拟真实环境下的挑战。该测试中,所有信号的采样频率设置为 20 000 Hz,比特率为 100 b/s,对应的比特时长为 0.1 s,每个测试中包含的比特数为 10 个,SNR 统一设置为 20 dB。


4 种常见调制方式(PSK、FSK、QAM 和 PM)信号在叠加白噪声后的时域波形表现如图 5 所示。可以看出,不同调制方式的信号在时域波形上表现出显著差异。PSK 信号整体波形平稳,主要以相位突变为主,易受相位扰动影响;FSK 信号在波形中呈现频率跳变特性,频率切换清晰可见;QAM 信号幅度和相位同时调




(a) 无噪声 FSK 信号



(b) FSK 信号+白噪声




(c) FSK 信号+瑞利噪声




(d) FSK 信号+莱斯衰落噪声


图 4 4 种仿真信号波形图



(a) PSK 信号+白噪声




(b) FSK 信号+白噪声



(c) QAM 信号+白噪声

赵建鼎,李靖超,赵静,等. 基于梳状滤波的改进 CNN-GRU 射频信号“基因”分类识别方法



(d) PM 信号+白噪声

图5 4种信号时域图

制,时域波形波动剧烈,具有较高的复杂度;PM 信号则以相位连续变化为特征,波形光滑但含有微小相位扰动。

将这4种不同的信号通过梳状滤波器进行频率增益提取射频基因后进行分类识别,结果表明,4种不同信号的分类识别率达到了100%,充分验证了系统在理想环境下对调制方式、模拟信号和数字信号的普适性。

2.2 基于实测信号的仿真结果与分析

本文构建了包含398个Wi-Fi模块(298个ESP-8266和100个RM28E)的大规模实测数据集。数据采集工作在4种典型通信环境下完成:1)实验室视距(LOS)环境,涵盖不同接收机(FSQ/FSW26/FSV13频谱仪)、传输信道(1~13信道)和采样率(20/40 MHz)组合;2)实验室多径环境;3)实验室非视距(NLOS)环境;4)微波暗室LOS环境。所有2.4 GHz频段的Wi-Fi Beacon帧I/Q信号均保持原始形态存储为结构化.xlsx文件,同时记录发射设备ID、信道参数、环境类型等元数据,构建了包含超过50万条样本的标注数据集,为模型训练与验证提供了完备的数据支撑。

实验随机选取实测信号中在微波暗室内的LOS环境下,采样率为40 MHz的10个2.4G ESP8266 Wi-Fi模块发射信号,1台FSV13频谱仪所接收的1000个样本信号进行仿真,验证提出方法的有效性,其中70%为训练集,20%为测试集,10%为验证集。

信号预处理是射频信号基因识别技术中的关键一步,其主要目的分为2个方面:一是从接收到的整段信号中选取合适的信号区间来作为样本;二是对信号进行去噪、部分均衡、调整信号中不同频率成分的相对强度。

一个完整的通信信号由3个特征迥异的组成部分构成:信道噪声、瞬态信号和稳态信号。信道噪声部分由信道自身噪声和设备产生的噪声组成,并不包含发射机发送的信息;瞬态信号出现在设备启停瞬间,虽携带独特电路特征但采集困难;而稳态信号作为设备持续发射段,具有易采集、信息完整的特点。本文主要从

分类识别和特征提取与分析这2个方面对上述不同类型的信号进行预处理:首先,将一段完整的Wi-Fi信号分为信道噪声部分、稳态信号部分以及整个Wi-Fi信号段作为样本,进行分类识别。通过这种方法,分别评估每种样本类型的识别率。另一方面,对Wi-Fi信号应用梳状滤波技术进行频率增益处理,从而放大并提取射频信号的基因特征。随后,使用皮尔逊相关系数将这些射频信号的基因特征绘制成图谱,以便于后续的分析 and 比较。全段信号、信道噪声部分、稳态信号部分绘制出的散点图如图6所示。可以看出,这3个部分的点密度分布存在明显差异。这说明每个部分所携带的射频信号基因特征信息具有显著的不同。






图6 Wi-Fi 信号散点图

原始I/Q双路信号和经过梳状滤波进行频率增益处理后的信号如图7所示。可以看出,相比原始I/Q双路信号,经过梳状滤波器对信号进行频率增益后,其幅值和波形分布有了明显的变化,射频信号基因特征得到增强。



(a) 原始信号时域波形



(b) 增益处理后的信号时域波形

图7 Wi-Fi 信号时域图

通过对12台同型号ESP8266 Wi-Fi模块(2.4 GHz频段)的射频信号基因图谱分析,发现图谱呈现特征性的环形拓扑结构,且不同区域间的密度分布存在差异,这些差异体现了不同的射频信号基因特征信息。对于

相同型号的物联网终端无线通信设备而言,本方法构建的基因图谱具有优异的类间分离度,能够有效区分不同型号设备的个体差异,为实现芯片级硬件指纹识别提供了可靠的技术途径。

在实测仿真验证过程中,首先将原始 I/Q 双路信号直接输入基准 CNN-GRU 模型(一维卷积结构),获得不同信号段的基线识别率;随后引入梳状滤波器进行频域特征增强,重点放大信号稳态段的特征成分。在网络架构方面实施了 3 个关键改进:1)将一维卷积扩展为二维结构,增强时-频特征提取能力;2)采用“最大池化+平均池化”的混合降维策略;3)通过激活函数对比实验,探索最佳配置。未进行预处理的样本分类实验结果如表 1 所示。

表 1 未进行预处理的样本分类实验结果

输入信号	持续时间/s	信道噪声/稳态信号/全段信号	识别准确率/%
I 路	8 300	信道噪声	83.26
Q 路	8 300	信道噪声	82.23
I/Q 双路	8 300	信道噪声	82.37
I/Q 双路加和	8 300	信道噪声	83.28
I 路	11 700	稳态信号	89
Q 路	11 700	稳态信号	86.90
I/Q 双路	11 700	稳态信号	88.68
I/Q 双路加和	11 700	稳态信号	88.60
I 路	20 000	全段信号	85.22
Q 路	20 000	全段信号	71.52
I/Q 双路	20 000	全段信号	84
I/Q 双路 加和	20 000	全段信号	75

由表 1 可知,识别准确率与输入信号的特性密切相关,特别是信道噪声、稳态部分及全段信号等特性对识别效果有显著影响。当全段信号作为输入样本时,信号的分路处理方式对实验的识别准确率有显著影响。然而,在针对信道噪声和稳态信号部分作为输入样本的实验中,信号的分路处理方式对识别准确率的影响并不如全段信号那样明显。进一步的实验分析揭示,Wi-Fi Beacon 帧的 I/Q 信号稳态部分在分类识别上表现出了最高的准确率。这一结果强调了稳态信号在物联网终端无线通信设备分类识别中的重要价值。稳态信号由于持续时间长,包含了相对完整的信号信息,因此在提取射频信号特征时具有显著优势。对于射频信号基因图谱的构建而言,稳态信号部分尤为重要。由于稳

态信号持续时间长,当这些信号被绘制成基因图谱时,能够提供更为完整和准确的射频信号基因信息。与信道噪声部分和信号瞬态部分相比,稳态部分不仅能更好地表示信号频率在一段时间内的变化,还能更准确地反映射频信号基因信息之间的相关性。因此,在物联网终端无线通信设备的分类识别任务中,稳态信号作为样本具有更高的利用价值。

为了改进原始 CNN-GRU 模型的有效性,本文将其与传统 CNN 模型和 ResNet-18 模型对信号稳态部分进行对比实验。其中,基于 ResNet-18 模型的识别准确率为 54.50%,基于 CNN 模型的识别准确率为 58%,本文提出的基于 CNN-GRU 模型的原始信号识别准确率为 88.68%,说明 CNN-GRU 模型相比于传统的深度学习网络模型在物联网终端无线通信设备的分类识别上具有更好的准确性和鲁棒性。

本文采用梳状滤波器对 Wi-Fi 信号进行频域特征增强,构建射频信号基因图谱,并输入改进的二维 CNN-GRU 模型进行测试,实验结果如表 2 所示。可以看出,稳态信号基因图谱的识别准确率达到 95.52%,较原始模型提升了 7%;全段信号识别准确率也提升至 93%。以上结果说明所提方法显著提升了设备识别性能。

表 2 CNN-GRU 多特征信号分类预测

输入信号	卷积层	识别准确率/%
信道噪声	convolution2dLayer	81.83
全段信号	convolution2dLayer	93
稳态信号	convolution2dLayer	95.52

本文将改进的 CNN-GRU 模型与 ResNet-18^[21]、CNN^[22]、LeNet-5^[23]这 3 种模型的识别准确率进行对比,结果如表 3 所示。可以看出,相比于其它 3 种模型,改进 CNN-GRU 网络模型的识别准确率提高了 5%~22%,且验证时间短。

表 3 4 种网络模型识别准确率

网络模型	输入信号	识别准确率/%	时间/s
CNN-GRU	稳态信号	95.52	0.310
LeNet-5	稳态信号	90.5	0.401
ResNet-18	稳态信号	73.4	0.620
CNN	稳态信号	82	1.02

3 结束语

本文提出了一种基于梳状滤波的改进 CNN-GRU

赵建鼎,李靖超,赵静,等. 基于梳状滤波的改进 CNN-GRU 射频信号“基因”分类识别方法

射频信号基因分类识别方法。该方法通过梳状滤波器对物联网终端无线通信设备信号进行频率增益提取,获取射频信号基因,并基于这一特性进行密度计算过滤,最终生成基因图谱。实验结果表明:改进 CNN-GRU 模型对同一制造商 10 台相同设备的 1 000 组数据识别准确率达到 95.52%,证实了基因图谱能有效表征设备信号特征。这一成果在提升无线通信设备识别准确性和物联网安全方面具有重要意义。

未来研究可深入探索基于生物基因特征的射频信号提取与融合算法,构建多级属性特征精细画像,并设计多粒度智能分类器,实现对物联网终端设备的智慧识别。这将有效解决设备克隆、身份假冒等安全问题,在保证识别准确性的同时显著提升计算效率。

参考文献:

- [1] SAHU A K, SHARMA S, TANVEER M, et al. Internet of things attack detection using hybrid deep learning model[J]. Computer Communications, 2021, 176: 146–154.
- [2] YADAV P, FERAUDO A, ARIEF B, et al. Position paper: a systematic framework for categorising IoT device fingerprinting mechanisms[C]//ACM. Proceedings of the 2nd international workshop on challenges in artificial intelligence and machine learning for internet of things (AIChallengeIoT 2020). Yokohama: ACM, 2020: 62–68.
- [3] DUAN C, GAO H, SONG G, et al. ByteIoT: a practical IoT device identification system based on packet length distribution[J]. IEEE Transactions on Network and Service Management, 2022, 19(2): 1717–1728.
- [4] DU R Z, ZHEN L. Multiuser physical layer security mechanism in the wireless communication system of the IIOT[J]. Computers & Security, 2022, 113: 102559–1–102559–11.
- [5] DU R, ZHEN L, LIU Y. Physical layer authentication based on integrated semi-supervised learning in wireless networks for dynamic industrial scenarios[J]. IEEE Transactions on Vehicular Technology, 2023, 72(5): 6154–6164.
- [6] ZHANG J H, XU Z J, LI J H, et al. Wi-Fi device identification based on multi-domain physical layer fingerprint[J]. Computer Communications, 2023, 204: 118–129.
- [7] SHAO Z, LV Z, WANG W, et al. Research on illegal mobile device identification based on radio frequency fingerprint feature[J]. Electronics, 2023, 12: 3144–1–3144–15.
- [8] TIAN Q, LIN Y, GUO X, et al. An identity authentication method of a MIoT device based on radio frequency(RF) fingerprint technology[J]. Sensors, 2020, 20: 1213–1–1213–18.
- [9] LI J C, YING Y L, JI C L, et al. Differential contour stellar-based radio frequency fingerprint identification for internet of things[J]. IEEE Access, 2021, 9: 53745–53753.
- [10] YING L, LI J, ZHANG B. Differential complex-valued convolutional neural network-based individual recognition of communication radiation sources[J]. IEEE Access, 2021, 9: 132533–132540.
- [11] 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.
- [12] SOLTANIEH N, NOROUZI Y, YANG Y, et al. A review of radio frequency fingerprinting techniques[J]. IEEE Journal of Radio Frequency Identification, 2020, 4(3): 222–233.
- [13] KUZDEBA S, ROBINSON J, CARMACK J. Transfer learning with radio frequency signals[C]//IEEE. Proceedings of 18th Annual Consumer Communications & Networking Conference(CCNC). Las Vegas: IEEE, 2021: 1–9.
- [14] LI J C, YING Y L, WANG S H, et al. Slice combination convolutional neural network based radio frequency fingerprint identification for Internet of Things[J]. Wireless Networks, 2023, 29(7): 2953–2966.
- [15] LI J C, YING Y L. A novel machine learning based fault diagnosis method for all gas-path components of heavy duty gas turbines with the aid of thermodynamic model[J]. IEEE Transactions on Reliability, 2024, 73(4): 1–14.
- [16] 王峰,李兴华,李晓龙,等. 基于健康画像的光通信设备故障预测算法[J]. 光通信技术, 2021, 45(9): 31–35.
- [17] YE J, GUO S S, ALOUINI M S. Joint reflecting and precoding designs for SER minimization in reconfigurable intelligent surfaces assisted MIMO systems[J]. IEEE Transactions on Wireless Communications, 2020, 19(8): 5561–5574.
- [18] 李怡蒙,方勇,刘峙杰. 基于星座图的数字信号调制方法综述[J]. 计算机系统应用, 2022, 31(12): 20–28.
- [19] 杨麒麟,刘俊,管坚,等. 基于深度强化学习的多目标跟踪技术研究[J]. 无线电通信技术, 2024, 297(1): 187–192.
- [20] WANG S Y, HUANG K Z, XU X M, et al. CSI-based physical layer authentication via deep learning[J]. IEEE Wireless Communications Letters, 2022, 11(8): 1748–1752.
- [21] EBRAHIMI A, LUO S, CHIONG R. Introducing transfer learning to 3D ResNet-18 for alzheimer's disease detection on MRI images[C]//IEEE. Proceedings of 2020 35th International Conference on Image and Vision Computing New Zealand(IVCNZ). Wellington: IEEE, 2020: 1–6.
- [22] PRASETHO S Y. Alzheimer's disease identification through brain MRI images: leveraging pretrained CNN Models [C]//IEEE. Proceedings of 10th International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA). Bandung: IEEE, 2024: 321–325.
- [23] ZHANG J, YU X, LEI X, et al. A novel deep LeNet-5 convolutional neural network model for image recognition[J]. Computer Science and Information Systems, 2022, 19(3): 1463–1480.