

DOI:10.19651/j.cnki.emt.2519653

基于改进型 LMMSE 信道估计的车联网射频 指纹识别方法*

盛丽娜¹ 徐耀^{1,2} 李燕^{1,2} 杨颀¹ 付楠¹

(1. 无锡学院物联网工程学院 无锡 214105; 2. 南京信息工程大学计算机学院 南京 210044)

摘要: 车联网场景下设备的移动性和复杂环境使其更易遭受恶意攻击,需要安全高效的认证机制,RFF为车联网身份认证提供了新的思路。但由于设备指纹特征直接从无线信号中提取,且其稳定性极易受到信道变化的影响,无线信道和接收机噪声的共同作用将导致接收到的信号发生失真,难以直接分离发射信号的真实特征。为解决上述问题,本文提出了一种基于改进型 LMMSE 信道估计的 PSBCH 的 RFF 提取方法。首先,本文构建了基于 LMMSE 准则的信道估计器。该估计器利用信道时频二维统计特性建立相应的二维相关矩阵,从而可有效捕获时间选择性衰落与频率选择性衰落之间的内在耦合关系,基于该矩阵能够有效地从接收信号中分离出随机信道响应。然后,通过信道均衡操作,对已被信道污染的硬件指纹进行还原,恢复指纹的原始特征信息。最后,通过结构优化的双分支异构神经网络对指纹进行深度表征学习,实现对硬件指纹的高精度分类。实验结果表明,在低信噪比的固定和移动场景下,所提方法的分类准确率分别达到 95.46% 和 92.05%。

关键词: 车联网;射频指纹;LMMSE;设备识别;神经网络

中图分类号: TN918 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Radio frequency fingerprint identification method for internet of vehicles based on improved LMMSE channel estimation

Sheng Lina¹ Xu Yao^{1,2} Li Yan^{1,2} Yang Yang¹ Fu Nan¹

(1. School of Internet of Things Engineering, Wuxi University, Wuxi 214105, China; 2. School of Computer Science, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: In Vehicle-to-Everything scenarios, the mobility of devices and the complexity of the environment render them more vulnerable to malicious attacks, necessitating a secure and efficient authentication mechanism. Radio Frequency Fingerprinting (RFF) offers a novel approach to identity authentication in V2X networks. However, as device fingerprints are extracted directly from wireless signals, their stability is highly susceptible to channel variations. The combined effects of the wireless channel and receiver noise cause distortion in the received signal, making it challenging to directly isolate the authentic features of the transmitted signal. To address these issues, this paper proposes an RFF extraction method based on an improved Linear Minimum Mean Square Error channel estimation for the Physical Sidelink Broadcast Channel. First, a channel estimator based on the LMMSE criterion is constructed. By exploiting the time-frequency two-dimensional statistical properties of the channel, a corresponding 2D correlation matrix is established, which effectively captures the intrinsic coupling relationship between time-selective and frequency-selective fading. Based on this matrix, the random channel response can be optimally separated from the received signal. Subsequently, a channel equalization operation is performed to recover the hardware fingerprints contaminated by the channel, restoring their original feature information. Finally, a structurally optimized dual-branch heterogeneous neural network is employed for deep representation learning and high-precision classification of these hardware fingerprints. Experimental results demonstrate that, under low signal-to-noise ratio conditions, the proposed method achieves classification accuracy of 95.46% and 92.05% in static and mobile scenarios, respectively.

Keywords: internet of vehicles; radio frequency fingerprint; LMMSE; device identification; neural network

0 引言

随着智能交通系统的快速发展,蜂窝车联网(cellular

vehicle-to-everything, C-V2X)技术已成为自动驾驶和智慧交通领域的关键技术之一^[1]。C-V2X 基于蜂窝通信网络,能够实现车辆与车辆、车辆与基础设施、车辆与行人以及车

收稿日期:2025-08-22

* 基金项目:无锡学院高层次人才科研启动专项经费(2024r001)资助

辆与网络之间的高效信息交互,为交通安全、效率和智能化提供了重要支撑^[2-3]。

然而,随着车联网应用的深入,数据传输的复杂性和网络规模的扩大导致安全问题日益凸显,其广播特性容易受到物理层攻击(如射频干扰、欺骗)以及协议漏洞的威胁。例如,EPS-AKA 认证机制中基于国际移动用户识别码和通用用户身份模块卡的加密机制,易受旁路攻击和拒绝服务攻击^[4-5]。传统密码学方法随着量子计算的发展面临破解风险,难以满足车联网高安全性的需求^[6]。射频指纹(radio frequency fingerprint, RFF)利用硬件固有缺陷(如 I/Q 失衡、功率放大器非线性等)作为不可克隆的物理标识,不仅规避了计算复杂度依赖问题,而且不可伪造性和唯一性使 RFF 成为设备识别和认证的优秀媒介^[7-8]。

在复杂的无线信道环境下,基于射频系统的鲁棒性容易受到影响。频选信道和时变信道很难直接提取出与信道特性解耦的纯净稳定的 RFF 特征,导致在多径和移动场景下识别性能较差。实验研究表明,信道干扰可直接导致 Wi-Fi 设备分类精度下降高达 80%^[9]。针对复杂信道变化对射频指纹特征稳定性的干扰问题,已有的研究主要集中在信道估计、数据驱动去噪、指纹特征鲁棒设计等方面。其中,信道估计方法基于信号处理的物理模型^[10-11],通过精确估计信道响应,再利用信道均衡等后续信号处理操作,将信道的影响从接收信号中“剥离”出去,从而还原出特征更纯净的发射信号指纹。该类方法的优势在于物理可解释性强,且利用每个接收帧自带的导频信号来实时估计当前信道^[12],对信道的动态变化具有自适应能力。然而,其过于依赖于信道模型,一旦实际信道特性与预设模型存在偏差(即模型失配),则将直接导致信道估计精度下降,进而影响 RFF 特征的还原效果。数据驱动去噪方法^[13-14]则是将信道干扰视为复杂且未知的非线性“噪声”函数。该类方法不依赖预设信道模型,而是利用深度神经网络非线性拟合能力,基于大量含噪数据训练干扰抑制模型。其优势在于对模型失配不敏感,且可以构建一个原始信号直接到设备标签的端到端模型。但是,该类方法严重依赖海量、多样化的训练数据,且可解释性差。

对于提取与信道无关的发射机固有特征^[15],部分文献指出利用载波频率偏移(carrier frequency offset, CFO)作为设备标识特征^[16-17],但其 CFO 存在时域稳定性不足与类区分度低等缺陷,在多径衰落及多设备共存场景下难以实现可靠的设备分类性能^[18]。还有部分研究集中于深度学习技术在射频指纹识别中的应用,基于对抗训练的数据驱动方法已成为当前的研究热点。Tsipras 等^[19]提出利用对抗样本作为增强数据,通过强正则化约束特征提取器,但此举会牺牲模型灵敏度与标准精度。而 Xie 等^[20]进一步引入解纠缠表示学习框架,通过对抗性训练与信号分解分离设备相关特征与信道相关分量,以抑制信道统计特性过拟合。

然而,上述方法多针对窄带或低移动性场景设计,难以

适配 C-V2X 的动态需求。尽管,目前已有研究尝试采用数据扩充方法^[21-22]和人工噪声添加方法^[23]缓解信道干扰,但前者显著增加模型训练开销,后者基于“接收信号=发射信号+RFF”的线性叠加假设,与物理层信号传输中信道畸变与硬件损伤的非线性耦合特性存在模型失配。此外, Wi-Fi^[24]、LoRa^[25]等系统虽能通过协议特定的帧结构特征实现信道补偿,但其方法论受限于无线通信标准的异构性,难以直接迁移至 C-V2X 系统架构。因此, Yin 等^[26]提出基于其物理随机接入信道瞬态特征的差分星座轨迹图构建方法,通过多通道卷积神经网络来提取瞬态启闭阶段的 RFF 特征,但实验表明其对解调参考信号等持续性符号特征的分类精度存在显著衰减。进一步地, Chen 等^[27]提出 LS 方法直接通过信道估计来去除无线信道的影响,但其信道估计仅仅依赖于导频数据,忽略噪声与信道特性。

为解决上述问题,本文提出了一种基于物理侧链路广播信道(physical sidelink broadcast channel, PSBCH)的射频指纹识别方法来实现 C-V2X 系统中的物理层安全。本文的主要贡献如下:

1) 提出一种基于时频二维线性最小均方误差(linear minimum mean square error, LMMSE)的信道优化指纹提取方法,构建一个能够同时捕获时间选择性衰落与频率选择性衰落间耦合关系的二维信道相关矩阵,并通过信道均衡操作生成初始指纹特征,以提高在复杂环境下指纹提取的鲁棒性。

2) 针对低信噪比(signal-to-noise ratio, SNR)和动态信道条件优化网络架构,设计一个双分支异构模型,其中 ShuffleNet V2 和 EfficientNet 两个分支分别侧重于指纹局部细节特征和全局特征的提取。在自适应加权融合后添加卷积块注意力模块(convolutional block attention module, CBAM)以突出关键的频谱特征,从而实现对手指特征的深度表征学习和高精度分类。

3) 在多种信噪比和移动性条件下进行了实验,结果表明本文所提网络模型相比于多个基准模型,在识别精度和鲁棒性上均表现出显著优势。在低信噪比移动场景下,依然能够保持高精度的识别效果,低信噪比静止和移动场景下,分类准确率分别达到 95.46% 和 92.05%。

1 系统概述

系统以物理侧行链路广播信道作为 RFF 提取源,通过协议特征与硬件特征的深度耦合,设计用于实现设备的分类任务。本节主要介绍 PSBCH 格式的结构和系统框架。

1.1 PSBCH

在副链路模式下,C-V2X 的传输技术主要是单载波频分多址(single carrier frequency division multiple access, SC-FDMA),支持 1.4、3、5、10、15、20 MHz 的 6 种带宽配置选项,分别对应采样点 1 920、3 840、7 680、11 520、15 360 和 30 720,本文选择最大带宽模式。在 C-V2X 通信场景

下,终端间相对运动速度峰值可达 500 km/h,且载波频率设定于 5.9 GHz,高速移动特性与高频载波的耦合作用将引发显著的多普勒频移效应,严重恶化信道估计精度与符号同步稳定性。为应对此挑战,C-V2X 协议针对 PSBCH 的帧结构进行了信道适应性优化设计,具体表现包括:1)导频增强,在每子帧内插入 3 个解调参考符号(demodulation reference signal,DMRS),分布于第 5、7、10 符号位置,以增强时变信道跟踪能力;2)保护间隔(guard period, GP)配置,将第 14 符号作为多径时延扩展的冗余缓冲,抑制符号间干扰。

如图 1^[28]所示,标准子帧由两时隙构成,其符号分配策略如下:主同步信号(primary sidelink synchronization signal, PSSS)与辅同步信号(secondary sidelink synchronization signal,SSSS)分别配置于第 2~3 符号与第 12~13 符号,实现快速时频同步;DMRS 集群(第 5、7、10 符号)提供高分辨率信道状态信息;GP 部署于第 14 符号以吸收多径能量;剩余符号为 PSBCH 符号。

1.2 系统框架

本研究所关注的 RFF 由发射机硬件电路的多种非理想特性构成,包括数模转换器的 I/Q 直流偏置、滤波器的频



图 1 物理侧链路广播信道子帧信号结构

Fig. 1 The structure of the subframe signal of the physical side link broadcast channel

率响应偏差以及功率放大器的非线性失真等,这些特性共同形成了设备独一无二的射频指纹。在信号传输过程中,V2X 终端(如车载单元 OBU 或路侧单元 RSU)通过无线信道向其他设备发送数据,其发射信号中内嵌固有的 RFF 特征。本文所提出方案的系统框架如图 2 所示。在接收端,信号首先经过预处理流程,包括信号的采集以及高精度的时频同步操作。基于同步信号,采用专门设计的算法提取 RFF 特征,并通过先进的信号处理技术有效抑制无线信道衰落与加性噪声对特征提取的干扰。本文还提出了一种双分支异构的分类神经网络架构,为实现设备身份的高精度鉴别。

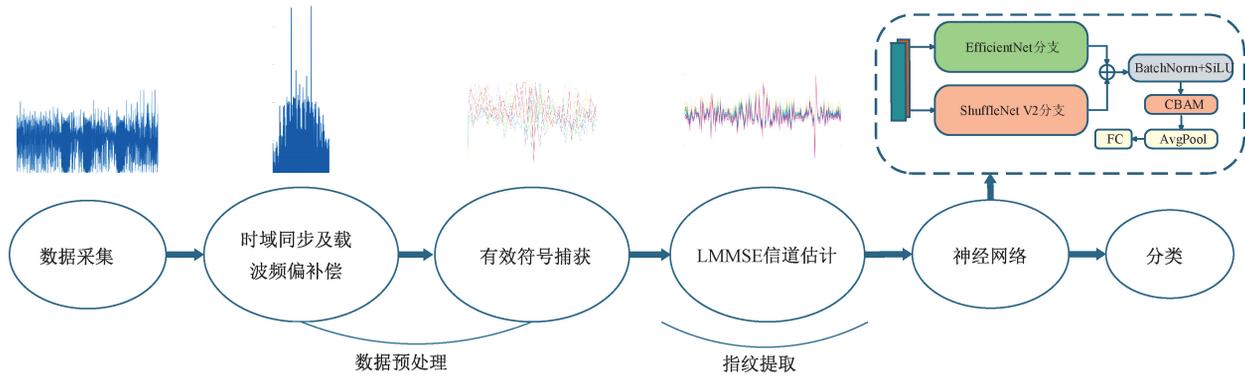


图 2 RFF 系统示意图

Fig. 2 Schematic diagram of RFF system

2 数据预处理

信号预处理部分主要包括信号检测、时间同步、载波频率偏移补偿等。

2.1 信号检测

在信号检测过程中,本文采用基于分块能量梯度与阈值判定的方法定位信号起始点,并通过动态截取策略确定有效信号段。定义信号分块长度为 W ,遍历接收信号 $y(n)$,其中 $n = 1, 2, \dots, N$,为基带信号长度。按分块长度 W 划分非重叠数据段,逐块计算能量 $e(k)$:

$$e(k) = \sum_{i=1}^{W} |y((k-1)W+i)|^2 = \mathbf{y}_k \mathbf{y}_k^H \quad (1)$$

其中, \mathbf{y}_k 为第 k 格数据块, i 为采样点索引,当相邻块能量比超过阈值,则可判定信号起始点位于 $n_0 = (k-1)W + 1$

附近,由此实现对目标信号段 N 的定位与检测。

2.2 帧同步

由于 PSBCH 特殊性,初始阶段设定快速傅里叶变换(fast Fourier transform,FFT)点数 N_{FFT} ,并定义第 m 个循环前缀长度为 G_m ,其中第 1 和第 8 个符号的 CP 长度为 160 样本,其余为 144 样本,符合侧链的正常 CP 配置。通过基于 PSSS 符号的强周期特性完成粗同步,加载本地生成的标准化 PSSS 序列 \mathbf{S}_{pss} 对接收信号进行幅度归一化互相关运算得到相关值 $R(i)$:

$$R(i) = \frac{\text{cor}\left(\frac{|\mathbf{y}(i:i+L-1)|}{\max(|\mathbf{y}(i:i+L-1)|)}\right)}{\max(|\mathbf{S}_{pss}|)} \quad (2)$$

其中, L 为相关窗口长度。随后通过搜索相关曲线的

峰值点 p_1 与 p_2 , 验证其间隔满足标准符号长度 2 048。随后, 基于循环前缀(cyclic prefix, CP)的细同步进一步优化同步精度, 在粗同步点附近定义局部搜索范围, 通过累加连续 M 格符号的 CP 互相关性 Γ 选择累加值最大的偏移作为最终同步点:

$$\Gamma = \sum_{m=1}^M | \text{cor}(\mathbf{y}(i_m : i_m + G_m - 1), \mathbf{y}(i_m + N_{\text{FFT}} : i_m + N_{\text{FFT}} + G_m - 1)) | \quad (3)$$

其中, m 是 OFDM 符号索引, M 为符号总数。

2.3 载波频偏补偿

载波频偏补偿的过程可以分为粗补偿和细补偿两个阶段。首先, 基于同步符号的粗补偿, 利用连续两个主同步符号相同以及连续两个辅同步符号相同的特性, 采用接收信号自相关的方法获得频偏估计值, 不需要重新生成基准序列, 提取信号段计算共轭互相关相位差估计频偏值 Δf_{sss} :

$$\Delta f_{\text{sss}} = \frac{1}{\pi N_{\text{sss}}} \arg \left\{ \sum_{n=0}^{N_{\text{FFT}}-1} [\mathbf{r}_2(n) \mathbf{r}_3^*(n)] + \sum_{n=0}^{N_{\text{FFT}}-1} [\mathbf{r}_{12}(n) \mathbf{r}_{13}^*(n)] \right\} \quad (4)$$

其中, $N_{\text{sss}} = 2\ 048$, 即两个重复的同步符号之间的时间间隔(以采样点计), $\mathbf{r}_2, \mathbf{r}_3$ 和 $\mathbf{r}_{12}, \mathbf{r}_{13}$ 分别为 PSSS 和 SSSS 的相关段。假设时域同步后信号为 $\mathbf{x}(n)$, 采样率为 $f_s = 30.72$ MHz, 则通过相位旋转补偿后的信号 $\mathbf{r}(n)$ 为:

$$\mathbf{r}(n) = \mathbf{x}(n) \cdot e^{-j2\pi\Delta f_n/f_s} \quad (5)$$

2.4 资源格解调

资源格解调作为从同步时域信号提取频域资源网格的核心步骤, 其会影响后续信道估计和数据解码的性能。针对每个符号, 解调过程采用为 $G_m \cdot 0.55$ 计算, 其中因子 0.55 确保 FFT 起始点位于循环前缀中部, 最大程度减少符号间干扰。解调时, 首先提取长度为 N_{FFT} 的时域样本段, 并于用于半子载波频偏补偿的因子 HF 相乘, 接着对补偿后的时域信号执行 FFT 变换, 将其转换到频域。为校正因 F_{start} 偏移引起的相位失真, 变换后的频域信号会进一步与相位补偿因子 PC 相乘, 并最终将零频分量移至中心。其中 HF 和 PC 定义为:

$$HF(i) = e^{(-j) \frac{\pi \cdot i}{N_{\text{FFT}}}} \quad (6)$$

$$PC(g) = e^{(j) 2\pi \frac{G_m - F_{\text{start}}}{N_{\text{FFT}}} \cdot g} \quad (7)$$

其中, g 为从 0~2 047 的索引, 第 m 个符号起始位置为 $F_{\text{start}}(m)$ 。该方法利用循环前缀的结构特性, 并通过相位和半子载波补偿来消除了时域偏移和子载波失调的影响, 得到频域资源。

3 指纹提取与分类

在设备识别任务中, 如何在有效减轻信道影响的同时, 完整地保留 RFF 特征, 是一个至关重要的问题。为实

现这一目标, 本部分采用 LMMSE 算法进行信道补偿并提取 RFF 特征。然后, 利用这些特征来训练神经网络, 以完成最终的设备识别任务。

3.1 信道估计与均衡

信道估计过程分为 3 个独立阶段, 分别对 PSSS、SSSS 和 DMRS。将经过预处理和 CP 去除后的接收到的 PSBCH 时域 SC-FDMA 符号变换到频域上, 加载预定义资源映射, 最小二乘估计方法通过这些参考信道的一致序列与接收信号的比值直接给出粗略的信道响应, 尽管最小二乘法简单, 但受噪声和多径效应的影响较大, 因此需进一步优化。在 C-V2X 系统中, 均方根(root mean square, RMS)时延扩展是信道估计中的关键参数, 尤其在基于线性最小均方误差的信道估计中, 用于构建信道自相关矩阵以提升估计精度。RMS 时延扩展反映了多径信道中各路径信号到达时间的分散程度, 直接影响信道的频率选择性衰落特性。以下详细说明其估算过程:

首先, 估计信道功率 σ_h^2 以表征信号能量, 公式为:

$$\sigma_h^2 = \max \left(\frac{1}{n \cdot N_c} \sum_{i=1}^{n \cdot N_c} | \mathbf{H}_{LS}(i) |^2 - \sigma_n^2, 0 \right) \quad (8)$$

$$N_c = \begin{cases} 62, C = 2, 3, 12, 13 \\ 72, C = 5, 7, 10 \end{cases} \quad (9)$$

其中, N_c 为子载波数。 $\mathbf{H}_{LS}(i)$ 为 H_{LS} 的展平向量, 若 C 为 2, 3 时, 即对应位置的 PSSS 符号, 包含 62 个子载波的两列, 共 124 个元素。 σ_n^2 为输入的噪声功率估计, 通过计算噪声段的平均能量估计噪声功率。减去 σ_n^2 后取非负值, 确保 σ_h^2 不为负, 为后续相关矩阵构建提供信道能量参数。将最小二乘估计结果 \mathbf{H}_{LS} 在符号维度上取平均, 平均多符号的最小二乘估计来平滑噪声, 增强信道响应可靠性。进行零填充后的逆快速傅里叶变换将频域的平均信道响应转换为时域信道冲激响应(channel impulse response, CIR), 表示多径信道中个路径的幅度和延迟信息。再调整 CIR 的零频位置, 确保时延对齐, 并计算功率时延谱 PDP 提供多径分量的能量分布, 则:

$$PDP = | CIR |^2 \quad (10)$$

其反映了信道时延特性, 并通过排除零填充引入的冗余数据, 保持时延分辨率与频域一致。为弱路径干扰, 通过估计信噪比 SNR_e 设置一个动态阈值 ts , 以聚焦于主要路径:

$$ts = \max(PDP) \cdot 10^{-\max(5, \text{SNR}_e)/10} \quad (11)$$

其中, 以最大值 PDP 为基准, 下降 $\max(5, \text{SNR}_e)$ dB 的幅度作为动态阈值, $\max(5, \text{SNR}_e)$ 确保最低 5 dB 衰减, 防止在低信噪比时阈值过高, 从而保留大量噪声分量。再对功率延迟分布进行归一化处理, 使其成为概率分布, 便于统计时延特性。假设时延向量为 τ , 则:

$$\tau(i) = i \cdot T_s \quad (i = 0, 1, \dots, N_c - 1) \quad (12)$$

其中, $T_s = 1/(N_c \cdot \Delta f)$ 是时域采样周期, $\Delta f = 15$ kHz 为子载波间隔, RMS 时延扩展 τ_{rms} 定义为时延的

均方根偏差,其计算公式为:

$$\mu_\tau = \sum_{i=0}^{N_c-1} PDP(i) \cdot \tau(i) \quad (13)$$

$$\tau_{rms} = \sqrt{\sum_{i=0}^{N_c-1} PDP(i) \cdot (\tau(i) - \mu_\tau)^2} \quad (14)$$

其中, μ_τ 是平均时延,即为功率延迟分布的时延期望值。其中若计算结果无效时,则采用默认值 $\tau_{rms} = 0.01 \mu\text{s}$,适用于低信噪比场景。

信道自相关矩阵 \mathbf{R}_{ff} 的构建基于均方根时延扩展,最后定义为:

$$\mathbf{R}_{ff}(p, q) = \sigma_h^2 \cdot \frac{1}{1 + j2\pi(p - q)\Delta f\tau_{rms}} \quad (p, q = 1, 2, \dots, N_c) \quad (15)$$

其中, $(p - q)\Delta f$ 为子载波相互之间的频率差,乘以 $2\pi\tau_{rms}$ 得到与时延相关的相位偏移。其模拟时延引起的相干带宽效应,适用于多径信道。为消除数值计算引入的误差,矩阵 \mathbf{R}_{ff} 经过厄米特对称形式调整,将其原始矩阵与其共轭转置矩阵相加后除以 2,确保矩阵保持正定性。考虑到车联网环境中信道估计过程受噪声和多径效应影响较大,尤其在低信噪比或复杂信道条件下,估计可能显著下降,为此引入基于相关矩阵 \mathbf{R}_{ff} 得到的先验信噪比 SNR_p 来优化 LMMSE 估计, SNR_p 综合了信道相关性和时延信息,反映更精确的信道统计特性:

$$\text{SNR}_p = \frac{\text{trace}(\mathbf{R}_{ff})/N_c}{\sigma_n^2} \quad (16)$$

然后生成动态调整正则化项 λ , 当 SNR_p 高时,减少正则化影响,保留信道细节,当 SNR_p 低时,增加正则化强度,增强矩阵稳定性。然后,通过下式计算第 i 个符号的频域信道估计:

$$\mathbf{W} = \mathbf{R}_{ff} \cdot (\mathbf{R}_{ff} + \sigma_n^2 \cdot \mathbf{I}(N_c))^{-1} \quad (17)$$

$$\mathbf{H}_{LM} = \mathbf{W} \cdot \mathbf{H}_{LS} \quad (18)$$

其中, \mathbf{W} 为权重矩阵,利用信道相关性校正 LS 估计中的噪声和系统误差,提升估计精度。由于 DMRS 并不是连续的正交频分复用(orthogonal frequency division multiplexing, OFDM)符号,移动导致的多普勒效应会使信道特性发生些许变化。针对 DMRS 的信道估计,本文利用信道的时频二维相关性对最初的 LS 信道估计矩阵进行优化。其中,频域相关矩阵 \mathbf{R}_{ff} 的构建与主/辅同步符号步骤相同。在构建时域相关矩阵 \mathbf{R}_{tt} 的过程中,先基于车辆相对运动速度 v 和载波中心频率 f_c 计算最大多普勒频移 f_{d_max} :

$$f_{d_max} = \left(\frac{v}{c}\right) \cdot f_c \quad (19)$$

其中, c 为光速。再根据计算所得最大多普勒频移 f_{d_max} , 利用零阶第一类贝塞尔函数 J_0 构建时域相关矩阵 \mathbf{R}_{tt} 来描述信道时间选择性衰落。矩阵中第 m 行第 n 列元素 $\mathbf{R}_{tt}(m, n)$ 的计算公式为:

$$\mathbf{R}_{tt}(m, n) = \sigma_h^2 \cdot J_0(2\pi \cdot f_{d_max} \cdot \Delta t(m, n)) \quad (20)$$

其中, $\Delta t(m, n)$ 为第 m 个和第 n 个 DMRS 符号在时域上的时间间隔。把得到的时域相关矩阵 \mathbf{R}_{tt} 和频域相关矩阵 \mathbf{R}_{ff} 进行 Kronecker 运算,将信道的时间和频率相关性融合成一个单一且完整的时频二维信道相关矩阵 \mathbf{R}_{2D} , 其计算公式为:

$$\mathbf{R}_{2D} = \text{kron}(\mathbf{R}_{tt}, \mathbf{R}_{ff}) \quad (21)$$

最后,构建二维滤波器权重矩阵 \mathbf{W} , 其计算公式为:

$$\mathbf{W} = \mathbf{R}_{2D} \cdot (\mathbf{R}_{2D} + \sigma_n^2 \cdot \mathbf{I}(N_c))^{-1} \quad (22)$$

其中, σ_n^2 为噪声功率, \mathbf{I} 为单位矩阵, $(\dots)^{-1}$ 表示矩阵求逆。二维滤波优化后的信道估计向量 \mathbf{H}_{LM_rec} 的计算公式为:

$$\mathbf{H}_{LM_rec} = \mathbf{W} \cdot \mathbf{H}_{LS_rec} \quad (23)$$

将信道估计向量 \mathbf{H}_{LM_rec} 变换为时频二维矩阵,得到最终的 DMRS 信道估计 \mathbf{H}_{LM} 。

在多径信道中, CIR 通常只集中在时域的少数样本上,这与 RMS 时延扩展有关,在 C-V2X 中,典型值范围为 $0.1 \sim 5 \mu\text{s}$,反映城市或高速公路环境中多径路径的短暂特性。相比之下,由于噪声和射频干扰在时域分布上较广,不具备 CIR 的集中性,可以继续将得到的频域信道估计 \mathbf{H}_{LM} 通过傅里叶逆变换转换到时域上,并对其进行加窗操作,以此来去除广范围的噪声和 RFF,使信道估计更加准确,这是因为噪声分量被抑制,而信道的主要多径路径得以保留。最后再将操作后时域估计通过傅里叶变换转到频域上,得到频域估计。

通过信道均衡技术移除信道信息,提取初始 RFF,经过预处理和 CP 去除及傅里叶变换后的第 C 个频域 SC-FDMA 符号的接收信号表示为 $\mathbf{Y}_c(k)$, 信道均衡操作具体可表示为:

$$\mathbf{R}(i) = \frac{\mathbf{Y}(i)}{\mathbf{H}_{LM}(i)} \quad (24)$$

进一步,可将信道处理后的指纹在后续所提的双分支神经网络中进行识别。图 3 为信道处理前后的指纹对比。其中,移动场景下和低信噪比场景下未经信道处理的指纹分别如图 3(a)和(c)所示,由于信道衰落和噪声的严重干扰,来自同一设备的指纹曲线离散度大且一致性差。图 3(b)和(d)展示了经过本文信道优化处理后的指纹,其曲线高度重合、形态稳定,描述了设备固有的指纹特征。

3.2 双分支异构网络模型

在 C-V2X 系统中,射频指纹识别技术利用物理层特征实现设备认证为车联网安全通信提供了重要保障。RFF 识别的性能高度依赖于特征提取的质量和分类模型的有效性。在传统射频指纹识别研究中,特征提取环节常采用单一网络架构实现。然而,任何单一网络均存在固有的归纳偏置,其设计逻辑决定了它更擅长捕捉某一特定类型的特征模式。当将这类单一网络单独应用于 RFF 识别任务时,这种内在的局限性会直接导致特征提取的覆盖性不足:

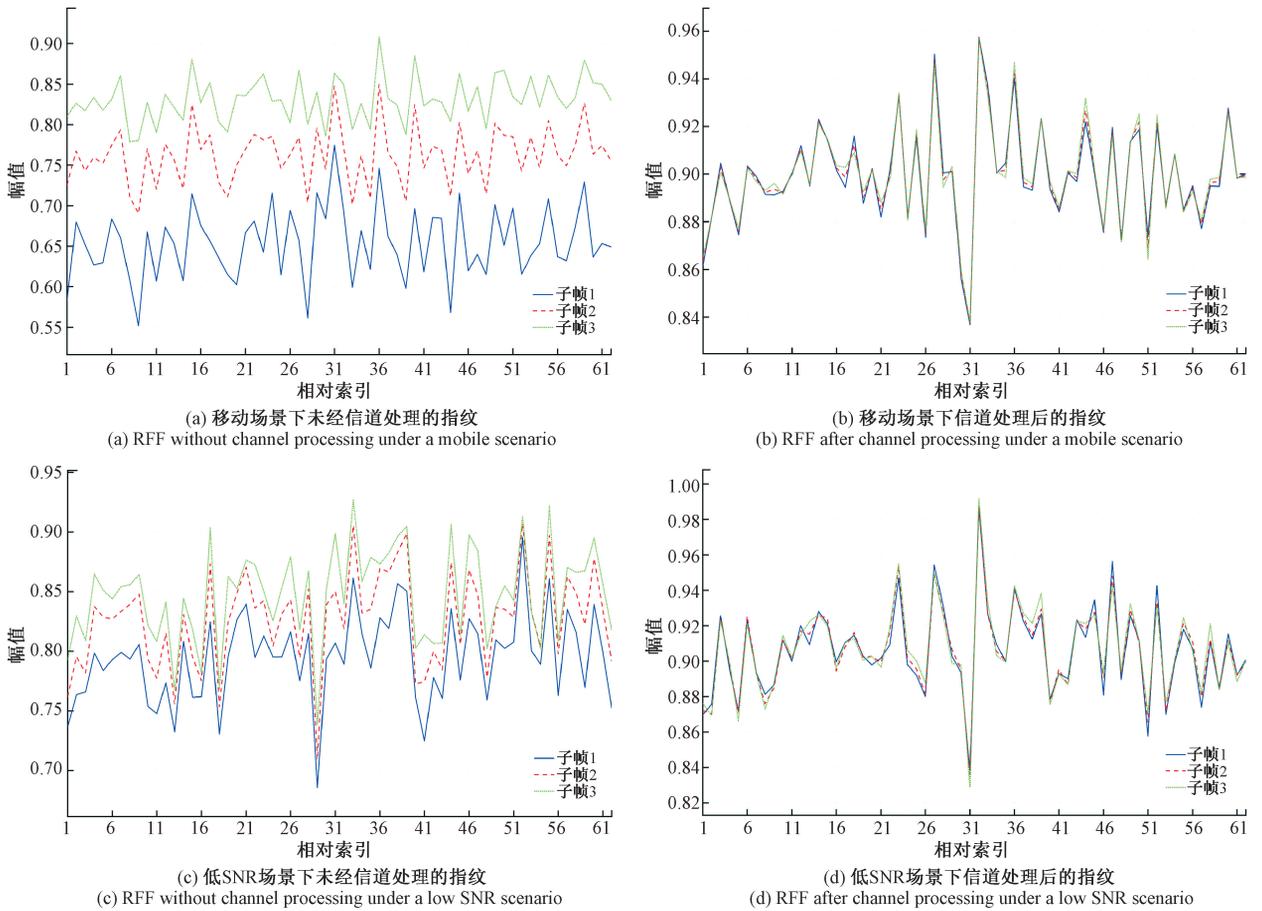


图3 信道处理前后的RFF对比

Fig. 3 Comparison of RFF before and after channel processing

难以全面捕捉复杂信道环境下RFF所呈现的多维度细微特性,进而影响后续识别任务的准确率与鲁棒性。

为此,本文提出了一种双分支异构网络模型,其架构如图4所示。其中,ShuffleNetV2分支侧重于提取RFF的局部细节特征,EfficientNet分支则侧重于提取全局特征。该模型利用网络分支的特征互补性,可构建更全面、鲁棒的RFF特征表示。ShuffleNet V2分支继承了ShuffleNet V1的轻量化设计理念,通过通道混洗和分组卷积,在较低的计算开销下,能更好地捕捉射频信号中的局部结构细节和低频细微变化^[29-30]。EfficientNet分支^[31-32]基于复合缩放原理,可有效地平衡网络的深度、宽度和分辨率,在捕捉频域信号的频谱结构与复杂的依赖关系上具有优势。然而,原始的ShuffleNetV2和EfficientNet均为二维图像分类任务设计。因此,本文对两个分支进行一维化适配改造以设计高效的特征融合策略,并引入注意力机制对融合后的特征进行筛选。

1) 网络架构设计

EfficientNet分支的核心计算单元为移动翻转瓶颈卷积(mobile inverted bottleneck convolution, MBConv)模块,具体如图5所示。该模块首先通过 1×1 逐点卷积对输

入通道进行扩展,随后利用高效的深度可分离卷积(depthwise convolution, DWConv)进行空间特征提取,并集成压缩和激励(squeeze-and-excitation, SE)模块以实现通道自适应加权,最后再通过 1×1 逐点卷积进行投影降维。考虑到车载环境的计算资源限制,本文未直接采用EfficientNet的基准网络配置,而是利用其复合缩放特性进行了调整。通过将宽度缩放系数和深度缩放系数均设置为0.3来减少网络的层数和每一层的通道数,从而在保持强大特征提取能力的同时,极大地降低了计算复杂度和内存占用。

ShuffleNet V2分支的核心单元如图6所示,该模块采用倒置瓶颈结构。首先,通过逐点卷积在扩展阶段增加通道数量。接着,利用深度可分离卷积提取针对一维频域数据的频域特定特征。最后,通过另一逐点卷积的线性瓶颈层降低计算复杂度。

当 $stride=1$ 情况下,通过通道分割来降低计算量,同时保留恒等映射以支持残差链接;当 $stride=2$ 情况下,通过两个分支处理特征尺寸并增加通道数。针对通道与层结构的调整如图4所示,将阶段2的块数设置为4,输出通道数为116,阶段3块数设置为8,输出通道数为232。调

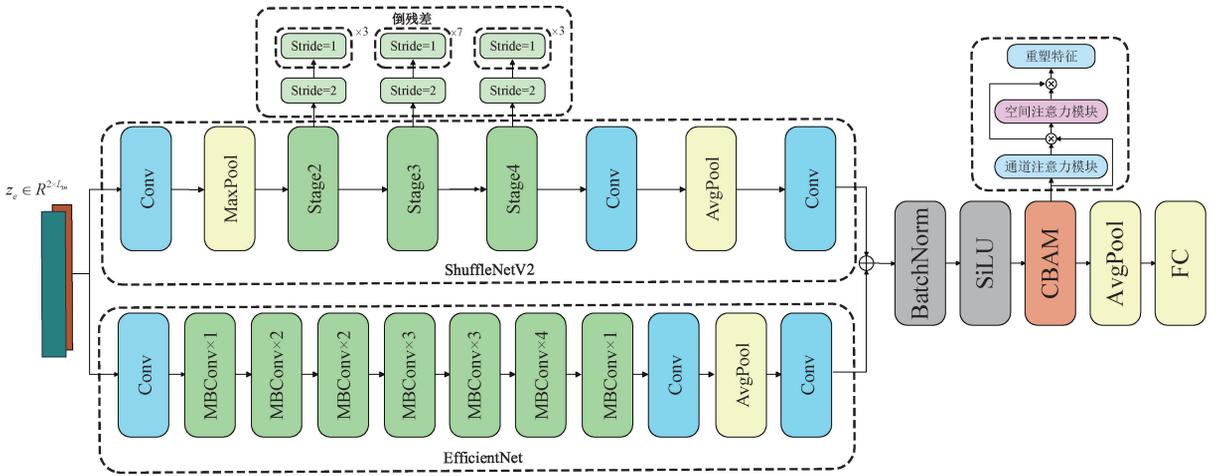


图 4 双分支异构神经网络架构

Fig. 4 Architecture of two-branch heterogeneous neural networks

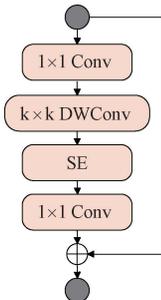


图 5 MBCConv 模块
Fig. 5 MBCConv module

整的网络结构增强了对频域信号深层模式的提取能力,特别适用于捕获设备间细微的频谱差异。通道调整提升了特征的多样性,使网络能够表示更多潜在的频域特征。阶段 4 保持 1 024 个通道,以在表达能力与计算成本之间取得平衡。

保留 ShuffleNet V2 的通道混洗操作,通过高效的特征融合缓解。设 B 为批量大小, G 为分组数, C 为通道数, L 为信号长度,在通道维度进行打乱时,具体的维度变换过程如下:

$$x = \text{Reshape}(x, [B, G, \frac{C}{G}, L]) \rightarrow \text{Transpose}(x, [1, 2]) \rightarrow \text{Flatten}(x, [B, C, L]) \quad (25)$$

自适应加权融合策略包括,初始化两个分别对应于 EfficientNet 分支和 ShuffleNet V2 分支的可学习标量权重参数 (e_w, s_w),然后融合特征图通过经过通道投影后的 EfficientNet 分支特征 e_o 和 ShuffleNet V2 分支特征 s_o 进行加权求和得到,其计算公式为:

$$Fused = e_w \cdot e_o + s_w \cdot s_o \quad (26)$$

所述权重参数在模型的训练过程中通过反向传播算法优化,从而使网络能够自动学习并调整各分支对最终决策的贡献度。

2) 注意力机制集成

使网络聚焦于对 RFF 识别至关重要的频域特征,本文在最终卷积层后集成了 CBAM^[33],其结合了通道注意力(channel attention, CA)和空间注意力(spatial attention, SA),通过自适应调整特征权重,突出关键的频谱特征。其实现过程如下:

通道注意力模块如图 7 所示,通过全局平均池化和全局最大池化提取通道特征,结合全连接层生成通道权重,公式为:

$$CA(X) = \sigma(W_2 \cdot \text{ReLU}(W_1 \cdot (\text{GAP}(X) + \text{GMP}(X)))) \quad (27)$$

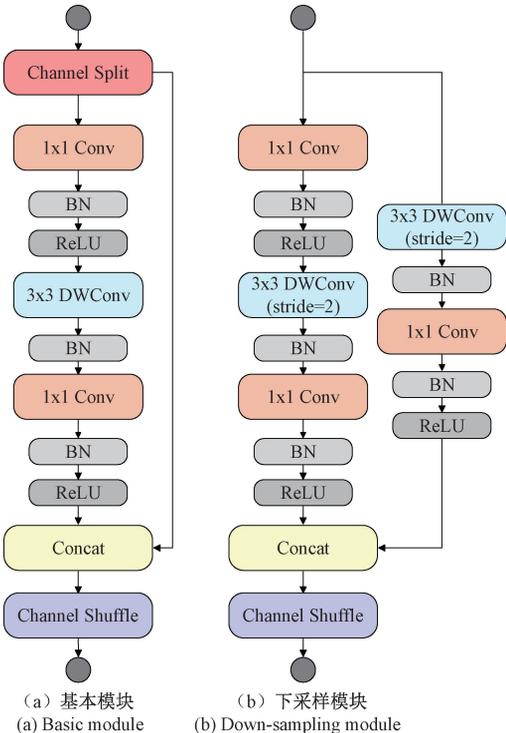


图 6 ShuffleNet V2 的核心单元

Fig. 6 The core unit of ShuffleNet V2

其中, X 为输入特征, GAP 与 GMP 分别为全局平均池化和全局最大池化, 通过两个全连接层进行降维和升维操作, 降维层 W_1 减少计算复杂度和升维层 W_2 恢复通道维度, σ 激活函数。

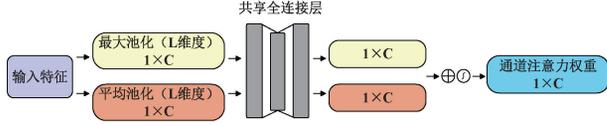


图 7 通道注意力模块

Fig. 7 Channel attention module

空间注意力模块如图 8 所示, 通过对特征图的一维空间结构建模, 聚焦于关键区域。在通道注意力加权后的特征图上, 通过沿通道维度的平均池化和最大池化生成空间特征, 再利用一维卷积生成空间权重, 公式为:

$$SA(X) = \sigma(\text{Conv1D}(\text{Concat}(\text{Mean}(X, 1), \text{Max}(X, 1)))) \quad (28)$$

$$X_{out} = X \cdot CA(X) \cdot SA(X) \quad (29)$$

通过 CA 和 SA 依次加权输入 X , 得到输出 X_{out} 。CBAM 通过通道和空间维度的联合优化, 使网络能够动态聚焦于 RFF 信号中的关键频谱特征。

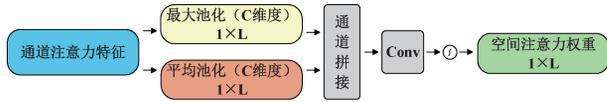


图 8 空间注意力模块

Fig. 8 Spatial attention module

4 实验结果

4.1 实验环境

本实验使用 12 台型号相同的 C-V2X 模块在 20 MHz 带宽下进行 PSBCH 子帧传输。信号接收采用美国 Ettus Research 公司生产的通用软件无线电外设备 (universal software radio peripheral, USRP) B205 mini-i, 其载波频率为 5.9 GHz 和采样率为 30.72 MSps。本文所涉及的数据采集主要在学校内部道路完成, 采集环境分为直连场景、静止场景和移动场景。其中, 静止场景包含视距传输 (LOS) 和由建筑物、植被遮挡形成的非视距传输 (NLOS)。移动场景为发射端以小于 30 km/h 的车速在校园内部道路行驶, 可进一步细分为 MOV1 (LOS)、MOV2 (NLOS) 和 MOV3 (LOS + NLOS)。上述采集过程中, 所发射的 PSBCH 都是随机化的, 各场景下的每个设备约能得到 1 000 个子帧, 对其进行预处理与指纹提取操作后, 构建训练数据集与测试数据集。

本文将长度为 186 (3 种符号的拼接) 的复数向量分解成实部与虚部, 形成一个维度为 $[2, 186]$ 的双通道实数张量作为网络的输入。本文实验所涉及的深度学习模型训练与测试均在同一性能计算平台上完成。该平台的硬件

配置为 Intel(R) Core(TM) i9-14900KF 中央处理器和一块拥有 24 GB 独立显存的 NVIDIA GeForce RTX 4090 图形处理器。软件环境方面, 实验在 Windows 11 操作系统下进行, 所有模型均使用 Python3.12 和编程实现, 并基于 PyTorch 2.7.1 深度学习框架进行搭建与训练。整个计算过程由 CUDA 12.6 提供加速支持。每个模型训练约 100 个 epochs, 选择具有最佳结果的模型用于测试。

4.2 评价标准

总体准确率 (overall accuracy) 被用作主要评估指标, 用于衡量每个场景下设备指纹的正确分类样本比例, 此外, 宏 F1 值 (macro-F1 score) 作为精准率 (precision) 和召回率 (recall) 的调和平均值, 评估模型在各类别间的平衡性能。

$$Accuracy = \frac{\sum_{i=1}^N TP_i}{\sum_{i=1}^N (TP_i + FN_i)} \quad (30)$$

$$Macro - Recall = \frac{1}{N} \sum_{i=1}^N Recall_i = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FN_i} \quad (31)$$

$$Macro - Precision = \frac{1}{N} \sum_{i=1}^N Precision_i = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i} \quad (32)$$

$$Macro - F1 = \frac{1}{N} \sum_{i=1}^N 2 \cdot \frac{Precision_i \cdot Recall_i}{Precision_i + Recall_i} \quad (33)$$

其中, TP_i 表示对于特定类别 i , 即实际属于类别 i 且被模型正确分类为类别 i 的样本, FP_i 是实际不属于类别 i 但被模型错误分类为类别 i 的样本, FN_i 即实际属于类别 i 但被模型错误分类为其他类别的样本, TN_i 表示实际不属于类别 i 的样本且被模型正确预测为其他类别的样本总数。

4.3 实验结果与讨论

1) 不同信噪比下分类

本节通过实验分析了两种信道估计方法在不同信噪比条件下的准确率表现。如图 9 所示, 在 SNR 从 0 ~ 30 dB 范围内的识别准确率变化趋势, 随着 SNR 的增加两种方法的准确率均呈现上升趋势。在低信噪比区域 (0 ~ 15 dB), 传统 LS 方法的性能受到限制。本文提出的方法其准确率曲线初始值更高, 且上升斜率更大。自相关性和噪声方差信息有效抑制了低信噪比下的噪声干扰, 在 SNR 仅为 5 dB 时准确率便已超过 90%, 在 SNR 在 5 dB 以下时, 准确率依旧达到 85% 以上, 显示出其在低信噪比下的鲁棒性优势。当 SNR 达到 20 dB 以上时, 两种方法的准确率均接近 100%, 但 LMMSE 保持轻微优势, 凸显其在复杂信道条件下的鲁棒性。

2) 不同场景下分类

表 1 给出了提出的信道估计后所提取的指纹在多场

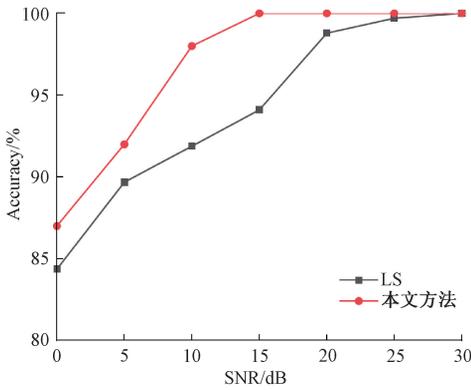


图 9 不同信噪比下的准确率

Fig. 9 Accuracy at different signal-to-noise ratios

景测试集下交叉认证结果,最高准确率为 100%,最低准确率为 93.06%。实验结果显示,不同训练集组合对测试集的分类性能影响显著。以直连场景为例,当训练集仅包含直连数据时,交叉认证准确率在 LOS、NLOS 和移动场景 (MOV1、MOV2、MOV3) 中分别为 98.19%、98.55% 和 99.2%、97.19%、98.07%,其中静止场景由于采集位置相同且信道一致,会导致信道均衡后所提取出的指纹缺少一定的区分性,因此本实验结果存在部分移动场景交叉实验优于静止场景的情况。但总体来看,不同训练集的组合对分类性能影响较为显著。

3) 不同模型对比实验

为了进一步评估所改进方法的通用性,本节与其他深度学习模型进行了对比分析,包括 DenseNet、EfficientNet、

表 1 不同场景下分类

Table 1 Classification under different scenarios

训练集	ACC/F1					%
	LOS	NLOS	MOV1	MOV2	MOV3	
直连	98.19/98.27	98.55/98.64	99.2/99.26	97.19/98.51	98.07/97.99	
MOV1	100/100	98.53/98.54	100/100	98.09/98.23	99.7/99.7	
MOV2	97.71/97.67	93.89/93.06	98.03/97.77	100/100	98.07/98.29	
MOV3	100/100	99.49/99.5	98.29/96.48	97.65/98.29	100/100	

MobileVit、ConvNeXt 和 ShuffleNet V2。表 2 给出了不同模型在移动场景下的性能表现。本文所提模型的总体准确率达到 99.2%,在宏精确率和宏 F1 值上也表现出色,优于其他模型。改进的信道估计为模型的输入提供更精确的设备指纹特征,引入较小计算开销的 CBAM 注意力机制增强了模型对区分性特征的关注能力,尤其在移动场景的复杂环境中。相比之下,DenseNet 尽管在计算效率上具有优势,但其宏精确率和宏 F1 值较低,表明在处理多场景指纹数据集时存在局限性。总体而言,本文模型保持

了与最轻量模型几乎相同的计算复杂度(FLOPs)。其推理时间为 6.3 ms,虽然略高于部分模型,但这主要是由双分支并行结构带来的额外内存访问开销,而非模型本身的计算冗余。采用本文所提网络模型,虽然需付出一定可承受的延时代价,但是能有效地提升分类性能。此外,现有模型多数依赖离线训练,而离线数据与现场数据的差异如设备老化等会导致模型在实际应用中的性能不佳,本模型拥有的轻量化特性使得其在现场训练和调整成为可能。

表 2 不同模型的对比

Table 2 Comparison of different models

深度学习模型	Accuracy/%	Macro Precision/%	Macro F1/%	Parameters/M	FLOPs/G	Time/ms
DenseNet	93.38	90.02	90.28	22.17	0.240	10.47
EfficientNet	93.73	91.39	92.25	3.88	0.030	3.93
MobileVit	80.91	81.08	77.67	2.44	0.030	4.84
ConvNeXt	96.21	95.40	96.32	85.38	1.711	5.27
ShuffleNet V2	92.54	93.20	93.09	1.25	0.010	3.09
本文模型	94.50	92.73	92.85	2.16	0.010	5.15
本文模型+CBAM	99.20	99.26	99.26	2.19	0.010	6.30

5 结 论

本文针对 C-V2X 环境下,提出并验证了一种基于信道

估计的 RFF 识别框架。在指纹提取阶段,利用信道协方差矩阵获取信道响应的统计特性。在指纹识别阶段,本文构建了一个双分支异构网络模型对指纹进行深度表征学习,

实现对硬件指纹的高精度分类。实验结果表明,该框架在低信噪比的固定和移动场景下均取得了较好的分类准确率。此外,通过在多种深度学习模型上的测试,证实了本框架所提指纹提取方法的通用性与可推广性。所提框架展现出的鲁棒性与轻量化特性,使其具备在真实车联网环境中进行现场训练与部署的潜力,为解决车联网安全认证问题提供了一种有效的技术方案。

参考文献

- [1] 陈山枝,葛雨明,时岩.蜂窝车联网(C-V2X)技术发展、应用及展望[J].电信科学,2022,38(1):1-12.
CHEN SH ZH, GE Y M, SHI Y. Development, application and prospect of Cellular Vehicle-to-Everything (C-V2X) technology [J]. Telecommunications Science, 2022, 38(1): 1-12.
- [2] 缪立新,王发平.V2X车联网关键技术研究及应用综述[J].汽车工程学报,2020,10(1):1-12.
MIU L X, WANG F P. Review on research and applications of V2X key technologies [J]. Chinese Journal of Automotive Engineering, 2020, 10(1): 1-12.
- [3] ZHOU H B, XU W CH, CHEN J CH, et al. Evolutionary V2X technologies toward the Internet of Vehicles: Challenges and opportunities [J]. Proceedings of the IEEE, 2020, 108(2): 308-323.
- [4] TAN ZH W, DING B Y, ZHAO J H, et al. Breaking cellular IoT with forged data-plane signaling: attacks and countermeasure[J]. ACM Transactions on Sensor Networks, 2022, 18(4): 1-26.
- [5] LUDANT N, ROBYNS P, NOUBIR G. From 5G sniffing to harvesting leakages of privacy-preserving messengers[C]. 2023 IEEE Symposium on Security and Privacy(SP). IEEE, 2023: 3146-3161.
- [6] ZHENG T X, WEN Y T, LIU H W, et al. Physical-layer security of uplink mmWave transmissions in cellular V2X networks [J]. IEEE Transactions on Wireless Communications, 2022, 21(11): 9818-9833.
- [7] 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.
- [8] 田金鹏,刘燕平,刘小娟.基于瞬态强度的射频指纹识别方法[J].电子测量技术,2016,39(4):58-61.
TIAN J P, LIU Y P, LIU X J. Radio frequency fingerprint identification method based on transient intensity [J]. Electronic Measurement Technology, 2016, 39(4): 58-61.
- [9] AL-SHAWABKA A, RESTUCCIA F, D'ORO S, et al. Exposing the fingerprint: Dissecting the impact of the wireless channel on radio fingerprinting[C]. IEEE INFOCOM 2020-IEEE Conference on Computer Communications. IEEE, 2020: 646-655.
- [10] 何炜航.面向LTE-V2X的稳态指纹提取方法研究与实现[D].南京:东南大学,2023.
HE W H. Research and implementation of steady-state fingerprint extraction method for LTE-V2X[D]. Nanjing: Southeast University, 2023.
- [11] 刘微.基于定位算法的光纤通讯信道干扰抑制方法[J].自动化与仪器仪表,2023(3):67-71.
LIU W. Interference suppression method for optical communication channel based on positioning algorithm[J]. Automation & Instrumentation, 2023(3): 67-71.
- [12] CHEN T SH, SHEN H, HU AI Q, et al. Radio frequency fingerprints extraction for LTE-V2X: a channel estimation based methodology[C]. 2022 IEEE 96th Vehicular Technology Conference (VTC2022-Fall). London: IEEE, 2022: 1-6.
- [13] HE H T, WEN CH K, JIN SH, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems [J]. IEEE Wireless Communications Letters, 2018, 7(5): 852-855.
- [14] HUANG H J, GUO S, GUI G, et al. Deep learning for physical-layer 5G wireless techniques: Opportunities, challenges and solutions [J]. IEEE Wireless Communications, 2019, 27(1): 214-222.
- [15] 曾浩南,谢跃雷.一种去信道指纹的信号辐射源识别方法[J].电子测量技术,2023,46(17):125-130.
ZENG H N, XIE Y L. A signal radiation source identification method for removing channel fingerprints[J]. Electronic Measurement Technology, 2023, 46(17): 125-130.
- [16] VO-HUU T D, VO-HUU T D, NOUBIR G. Fingerprinting Wi-Fi devices using software defined radios [C]. 9th ACM Conference on Security & Privacy in Wireless and Mobile Networks, 2016: 3-14.
- [17] HUA J Y, SUN H Y, SHEN ZH Y, et al. Accurate and efficient wireless device fingerprinting using channel state information[C]. IEEE INFOCOM 2018-IEEE Conference on Computer Communications. IEEE, 2018: 1700-1708.
- [18] XING Y X, HU AI Q, ZHANG J Q, et al. Design of a channel robust radio frequency fingerprint identification scheme [J]. IEEE Internet of Things Journal, 2022, 10(8): 6946-6959.
- [19] TSIPRAS D, SANTURKAR S, ENGSTROM L, et

- al. Robustness may be at odds with accuracy[J]. ArXiv preprint arXiv:1805.12152, 2018.
- [20] XIE R J, XU W, YU J B, et al. Disentangled representation learning for RF fingerprint extraction under unknown channel statistics [J]. IEEE Transactions on communications, 2023, 71 (7): 3946-3962.
- [21] AL-SHAWABKA A, PIETRASKI P, PATTAR S B, et al. DeepLoRa: Fingerprinting LoRa devices at scale through deep learning and data augmentation [C]. Twenty-second International Symposium on Theory, Algorithmic Foundations, and Protocol Design for Mobile Networks and Mobile Computing, 2021: 251-260.
- [22] SOLTANI N, SANKHE K, DY J, et al. More is better: Data augmentation for channel-resilient RF fingerprinting[J]. IEEE Communications Magazine, 2020, 58(10): 66-72.
- [23] ZHOU X Y, HU AI Q, LI G Y, et al. A robust radio-frequency fingerprint extraction scheme for practical device recognition [J]. IEEE Internet of Things Journal, 2021, 8(14): 11276-11289.
- [24] LI G Y, YU J B, XING Y X, et al. Location-invariant physical layer identification approach for WiFi devices[J]. IEEE Access, 2019, 7: 106974-106986.
- [25] SHEN G X, ZHANG J Q, MARSHALL A, et al. Towards scalable and channel-robust radio frequency fingerprint identification for LoRa [J]. IEEE Transactions on Information Forensics and Security, 2022, 17: 774-787.
- [26] YIN P CH, PENG L N, ZHANG J Q, et al. LTE device identification based on RF fingerprint with multi-channel convolutional neural network[C]. 2021 IEEE Global Communications Conference (GLOBECOM). IEEE, 2021: 1-6.
- [27] CHEN T SH, SHEN H, HU AI Q, et al. Radio frequency fingerprints extraction for LTE-V2X: A channel estimation based methodology[C]. 2022 IEEE 96th Vehicular Technology Conference (VTC2022-Fall). IEEE, 2022: 1-6.
- [28] ETSI 3rd Generation Partnership Project. LTE; evolved universal terrestrial radio access(E-UTRA); physical channels and modulation (Release 14) [S]. Sophia Antipolis Cedex, Biarritz, France, 3GPP TS 36.211 Version 14.2.0, 2016.
- [29] MA N N, ZHANG X Y, ZHENG H T, et al. Shufflenet v2: Practical guidelines for efficient cnn architecture design [C]. European Conference on Computer Vision(ECCV), 2018: 116-131.
- [30] ZHANG X Y, ZHOU X Y, LIN M X, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.
- [31] TAN M X, LE Q. Efficientnet: Rethinking model scaling for convolutional neural networks [C]. International Conference on Machine Learning. PMLR, 2019: 6105-6114.
- [32] 吕游,郑茜,齐欣宇,等.基于改进 EfficientNet 的红外图像光伏组件故障识别研究[J].仪器仪表学报,2024, 45(4):175-184.
- LYU Y, ZHENG X, QI X Y, et al. Research on fault identification of photovoltaic modules in infrared images based on improved EfficientNet[J]. Chinese Journal of Scientific Instrument, 2024, 45 (4): 175-184.
- [33] 王宸,杨帅,周林,等.基于自适应多尺度特征融合网络的金属齿轮端面缺陷检测方法研究[J].电子测量与仪器学报,2023,37(10):153-163.
- WANG CH, YANG SH, ZHOU L, et al. Research on metal gear end-face defect detection method based on adaptive multi-scale feature fusion network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(10): 153-163.

作者简介

盛丽娜,博士,讲师,主要研究方向为物联网系统安全、网络攻击检测。

E-mail:linasheng01@126.com

徐耀,硕士研究生,主要研究方向为射频指纹识别技术、车联网安全。

E-mail:202412492590@nuist.edu.cn

李燕(通信作者),博士,教授,主要研究方向为机器学习、计算机视觉。

E-mail:002200@nuist.edu.cn

杨颺,博士,讲师,主要研究方向为设备物理层安全。

E-mail:yangyang@cw Xu.edu.cn

付楠,博士,讲师,主要研究方向为机器学习、隐私保护。

E-mail:funan1988@cw Xu.edu.cn