

基于置信度差异与熵最小化的跨时间鲁棒射频指纹识别方法

张杰¹, 王琴¹, 尹悦², 王禹¹, 桂冠¹

(1.南京邮电大学通信与信息工程学院, 江苏 南京 210003; 2.日本庆应义塾大学信息与计算机科学系, 横滨 229-1293)

摘要: 在真实无线电磁环境中, 射频指纹识别系统常受到信道条件和环境因素随时间变化的影响, 导致训练阶段与测试阶段数据分布不一致, 从而引发显著的跨时间域性能退化问题, 严重制约模型在未知场景下的稳定性与泛化能力。针对上述问题, 提出一种面向跨域泛化的射频指纹识别测试时自适应方法, 该方法在不依赖目标域标注数据的情况下, 通过在测试阶段对模型进行自适应调整, 以缓解由环境变化引起的域偏移影响。首先, 针对复杂信道条件下射频指纹特征易受干扰的问题, 构建了一种基于并行多尺度卷积 (Inception) 结构的射频指纹识别网络, 通过多尺度特征提取增强指纹特征的鲁棒性与稳定性。其次, 针对测试阶段难以获取源域数据及目标域标签的问题, 设计了一种无源无监督的测试时自适应框架, 使模型能够在测试过程中逐步适应目标环境的分布变化。实验结果表明, 所提方法在多个公开数据集上均取得了优于对比方法的识别性能, 并在跨时间域场景下展现出良好的稳定性与泛化能力, 为射频指纹识别在真实复杂环境中的应用提供了有力支撑。

关键词: 物理层安全; 射频指纹识别; 深度学习; 测试时自适应; 无源无监督域适应

中图分类号: TN92

文献标志码: A

DOI:10.11959/j.issn.1000-436x.2026012

Robust RF fingerprint identification under temporal domain shifts via confidence discrepancy and entropy minimization

Zhang Jie¹, Wang Qin¹, Yin Yue², Wang Yu¹, Gui Guan¹

1.College of Telecommunications & Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2.Department of Information and Computer Science, Keio University, Yokohama 229-1293, Japan

Abstract: In real-world wireless electromagnetic environments, radio frequency fingerprint (RFF) identification systems are inevitably affected by time-varying channel conditions and environmental changes, which lead to distribution mismatch between training and testing data. Such mismatch causes notable performance degradation across time-varying scenarios, severely limiting the stability and generalization capability of RFF identification models in unknown environments. To address this challenge, a cross-domain generalization-oriented test-time adaptation method for RFF identification was proposed. The proposed approach did not rely on labeled target-domain data and mitigated environment-induced domain shifts by adaptively updating the model during the testing phase. Firstly, an Inception-based RFF identification network was designed to enhance the robustness of fingerprint features under complex channel conditions by exploiting multi-scale feature representations. Secondly, considering the practical constraint that neither source-domain data nor target-domain labels were accessible during testing, a source-free and unsupervised test-time adaptation framework was developed, enabling the model to progressively adapt to the target-domain distribution. Experimental results on multiple public datasets demonstrated that the proposed method achieved superior identification performance compared with existing approaches, while maintaining strong robustness and generalization capability in cross-time scenarios. These results validate the effectiveness of the proposed method for practical RFF identification deployment in complex environments.

Keywords: physical layer security, radio frequency fingerprint identification, deep learning, test-time adaptation, source-free unsupervised domain adaptation

收稿日期: 2025-09-25; 修回日期: 2026-01-13

通信作者: 桂冠, guiguan@njupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62471247, No.62401281, No.62472019)

Foundation Items: The National Natural Science Foundation of China (No.62471247, No.62401281, No.62472019)

0 引言

在无线通信系统中，设备身份认证在确保信息安全方面起着至关重要的作用。攻击者能够借助不可靠的设备认证机制伪装成合法设备进入通信系统，这将导致严重的安全问题，例如数据泄露、恶意攻击和信息窃取等^[1-2]。传统的设备认证方法大多基于 MAC 地址、密码学以及共享数字密钥，然而这些方法通常具有高复杂度和高计算量，且非常容易受到窃取、伪造和干扰，因此具有一定的局限性^[3-5]。在此背景下，射频指纹（radio frequency fingerprint, RFF）识别作为一种可靠的基于物理层的设备认证技术应运而生，它利用无线设备在制造过程中产生的独特的、固有的硬件缺陷来识别设备身份，例如振荡器频率偏移、功率放大器（power amplifier, PA）非线性以及同相/正交（in-phase/quadrature, I/Q）不平衡^[6-8]，如图 1 所示，关键组件包括数模转换器（digital-to-analog converter, DAC）、中频（intermediate frequency, IF）滤波器、射频（radio frequency, RF）滤波器等。这些硬件缺陷将导致无线设备发射出的无线信号表现出独特的非线性失真，这些失真使得接收端能够从中提取出信号独有的 RFF 特征，这些特征非常难以复制或者伪造，进而能够被用于设备认证。

近年来，基于深度学习（deep learning, DL）的 RFF 识别方法凭借其强大的特征提取能力及更低的计算复杂度，逐渐取代传统的手动信号处理方法^[9-11]。它的核心在于训练深度神经网络（deep neural network, DNN），例如卷积神经网络（convolutional neural network, CNN）^[12]、长短时记忆网络（long short term memory network, LSTM）^[13]以及 Transformer^[14]网络等，从无线信号中自动提取

复杂的 RFF 特征并分类。一般而言，基于 DL 的射频指纹识别过程包括两个典型步骤，即源域离线预训练和目标域在线测试。在跨域射频指纹识别任务中，通常将模型训练时所依赖的数据分布或采集环境称为源域，而将模型最终需要应用或测试的数据分布称为目标域。无线信道条件、接收设备差异及噪声环境等因素，源域数据与目标域数据之间往往存在显著分布差异，这种分布偏移会导致模型在目标域上的识别性能显著下降。目前大多数的射频指纹识别研究都假设源域和目标域具有相同的数据分布，然而在真实电磁环境中，信道及环境变化导致的域偏移问题始终存在，且以时间域偏移最为常见^[15-16]。因此，射频指纹识别的无监督域适应（unsupervised domain adaptation, UDA）问题受到广泛关注，其目的在于将射频指纹识别 DNN 从源域中学习到的知识迁移到一个未知的目标域，且不需要目标域数据的任何标签信息^[17-18]。与同样受到广泛关注的域泛化方法不同的是，无监督域适应侧重于在目标域中通过源域的知识进行自适应，以实现目标域识别能力的提升，而域泛化方法则旨在使模型能够在多个未知目标域上表现出色，它通过在训练过程中引入多个源域的分布信息，避免在目标域中出现过拟合问题，从而实现模型的泛化能力提升。因此，UDA 关注的是如何在单一目标域上进行有效的适应，而域泛化则更侧重于模型在多个目标域上的普适性和鲁棒性。本文主要提出一种仅在目标域上实现的域适应算法。

标准的 UDA 方法假设在模型适应过程中，源域及目标域数据都是可访问的。然而，在真实的非合作场景中，由于隐私、机密性等问题，源域数据通常是无法访问的^[19]。近年来，为了解决这个问

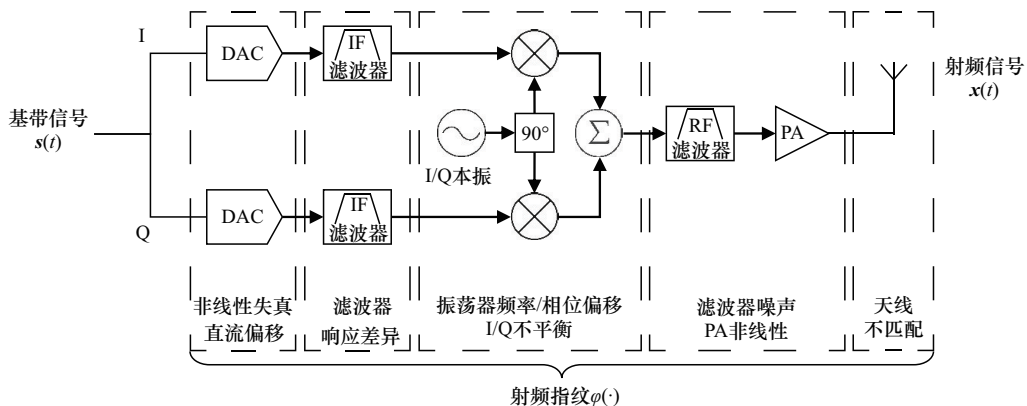


图 1 发射机射频指纹机理

题, 无源无监督域适应 (source-free unsupervised domain adaptation, SFUDA) 方法已经在目标检测、语义分割以及图像分类领域被广泛应用^[20], 然而在射频指纹识别中该问题同样存在, 但相关研究十分匮乏。一方面, 现存的大多数射频指纹识别 SFUDA 方法基于自监督学习 (self-supervised learning, SSL)、伪标签以及统计分布对齐^[21-23], 其中, 基于 SSL 的方法通常需要大规模训练数据, 基于伪标签的方法难以克服过度自信的问题, 基于统计分布对齐的方法则存在协变量偏移等问题, 导致模型在分布不一致或测试场景发生快速变化时难以保持稳定性能^[24-25]。另一方面, 现存的射频指纹识别 SFUDA 方法通常需要一个稳定的迭代训练过程使模型有效地适应到新的目标域, 会伴随着大量的适应时间及计算资源需求。然而, 在复杂的动态的真实电磁环境中, 数据分布存在连续的不可预测的偏移, 限制了这些方法的有效性和鲁棒性。综上, 实现计算开销较低且具有实时性的射频指纹识别域适应方法仍然是一个重大的挑战。

跨时间分布偏移往往会导致模型在目标域样本上的预测不确定性显著增大, 而预测置信度差异与输出熵能够有效刻画样本受分布变化影响的程度。通过优先选取置信度较高、判别结果相对稳定的关键样本, 并在此基础上最小化预测熵, 可在不依赖目标域标签的前提下, 引导模型逐步向低不确定性、高一一致性的判别状态收敛, 从而实现目标域数据结构的自适应对齐。因此, 本文搭建了一个从源域有监督预训练到目标域无源无监督自适应的跨时间鲁棒 RFF 识别框架, 并提出一种面向跨域泛化的 RFF 识别测试时自适应方法。该方法本质上属于一种适用于测试阶段的实时 SFUDA 策略, 在保证识别性能鲁棒性的同时, 有效控制了额外计算开销。首先基于置信度差异的样本筛选机制筛选出受跨时间数据分布差异影响的关键样本, 进一步借助模型输出结果的熵得分来驱动一个基于并行多尺度卷积 (Inception) 结构的跨时间鲁棒 RFF 识别网络 (cross-time robust RFF identification network, CT-RFFNet), 实现有效的模型跨时间域测试时自适应。本文主要贡献如下。

1) 提出了一种面向跨域泛化的 RFF 识别测试时自适应方法, 该方法包含两个关键步骤: 基于置信度差异的测试样本筛选、基于熵最小化的测试时

自适应。

2) 提出了一个基于 Inception 结构的跨时间鲁棒 RFF 识别网络。CT-RFFNet 包含多个改进的 Inception 模块, 借助不同大小卷积核形成多感受野对信号样本进行有效的 RFF 特征提取, 并实现特征信息聚合。与广泛应用于 RFF 识别的骨干网络模型对比, 该网络具有最优的基础泛化性能。

3) 在两个开源数据集 ORACLE 和 WiSig 上验证了所提方法在解决跨时间鲁棒射频指纹识别实时域适应问题上的有效性。给定相同骨干网络并设置相同实验条件, 相较于次优方法, 所提方法可进一步提升平均识别准确率, 在 ORACLE 数据集上可提升至约 85%, 在 WISIG 数据集上可提升至约 97%。

1 系统模型

基于 DL 的射频指纹识别在提升物理层安全方面发挥着关键作用, 因其较传统方法而言复杂度低且特征提取能力强, 被广泛用于物理层设备认证。一个典型的基于 RFF 的物理层设备认证系统如图 2 所示, 主要包括 3 个部分: 信号接收与预处理、RFF 特征提取, 以及 RFF 特征库的建立或未知设备识别。在信号接收与预处理阶段, 主要包括信号采样、时间同步、频偏相偏补偿、IQ 数据归一化等步骤。随后, 通过 RFF 特征提取器从处理后的信号中提取 RFF 特征。由于应用场景的差异, RFF 特征可能来源于已知或未知的发射源。对于已知发射源, 其 RFF 特征被归类并标注, 存入 RFF 数据库。相反, 对于未知发射源, 其 RFF 特征将与数据库中的记录进行匹配, 以生成关于其认证状态的反馈信息。接收到的射频信号可以定义为

$$x(t) = \psi\left(c(t) * \varphi\left(s(t) \cos(\omega_0 t + \theta)\right)\right) + n(t) \quad (1)$$

其中, $*$ 表示卷积运算, $s(t)$ 为调制信号, 其载频为 ω_0 , $c(t)$ 表示信道响应, $n(t)$ 为信道噪声。 $\varphi(\cdot)$ 和 $\psi(\cdot)$ 分别表示对发射机和接收机的“射频指纹”进行建模的两个非线性函数, 对不同的发射机及接收机而言, 其非线性函数是完全不同的。数据预处理阶段, 连续信号 $x(t)$ 将被采样为离散信号样本 $x[n]$, 可以表示为

$$x[n] = x(nT_s), n \in \{0, 1, \dots, N-1\} \quad (2)$$

其中, T_s 表示采样间隔, N 表示离散样本长度。

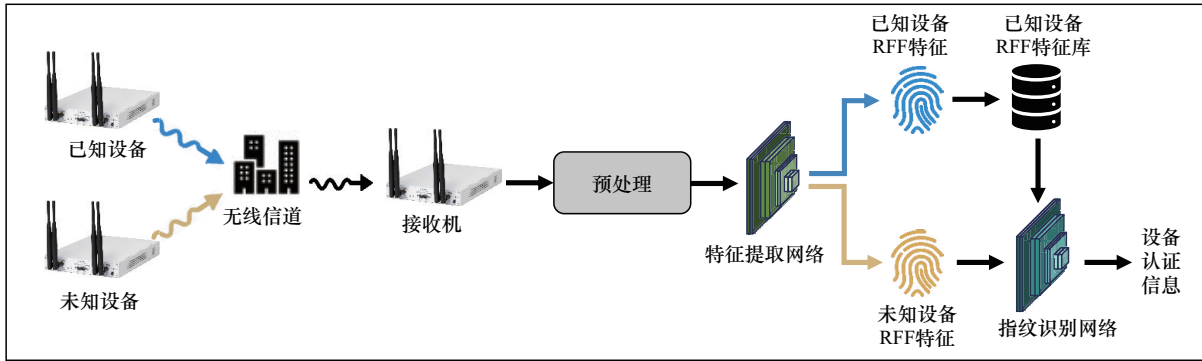


图2 基于RFF的物理层设备认证系统

2 跨时间鲁棒射频指纹识别方法

2.1 整体架构

本文方法整体架构如图3所示，主要包含3个关键步骤：1) 源域预训练，基于源域有标签数据充分预训练一个CT-RFFNet，获取其模型权重用于目标域模型的初始化；2) 基于置信度差异的样本筛选，利用源域模型及目标域模型推理结果进行置信度对比，筛选出适合进行熵最小化的测试样本；3) 基于熵最小化的测试时自适应，在筛选出的测试样本上计算其熵损失并更新目标域模型的批归一化（batch normalization, BN）层，同时获得模型实时推理结果。

2.2 源域预训练

2.2.1 信号预处理

如图3所示，接收端在时间A采集无线设备发射的信号样本将作为源域，进行预处理后构建一个源域数据集 \mathcal{D}_s 。信号预处理旨在最大化保留射频信号中的独特指纹信息，减轻因无线信道中复杂多变因素导致的指纹失真，从而避免模型过拟合或学

习到与信道相关的无效特征，具体步骤包括时间同步、载波频偏补偿和能量归一化。

2.2.2 CT-RFFNet

数据预处理完成后，骨干网络的搭建至关重要，因为其在目标域中的测试表现与其基础泛化性能直接相关，尤其在对特征强动态性的真实电磁环境中。Inception结构首先由Szegedy等^[26]提出，通过并行的多尺度卷积核在同一层内对信号进行特征提取，以增强网络对不同时间尺度和频率特征的感知能力。后续Fawaz等^[27]在Inception结构基础上发展形成的一类时间序列建模网络，通过堆叠多个Inception模块并结合残差连接来增强特征表达与训练稳定性，提出的InceptionTime网络在时序分类任务上性能优越。受此启发，本文提出了一种专门针对RFF识别信号特性的跨时间鲁棒识别网络，即CT-RFFNet。其结构如图4所示，由4个Inception块和一个头部块组成。Inception块利用多个不同大小的卷积核形成多感受野，有效提取信号中的RFF特征。头部块则借助自适应平均池化（adaptive aver-

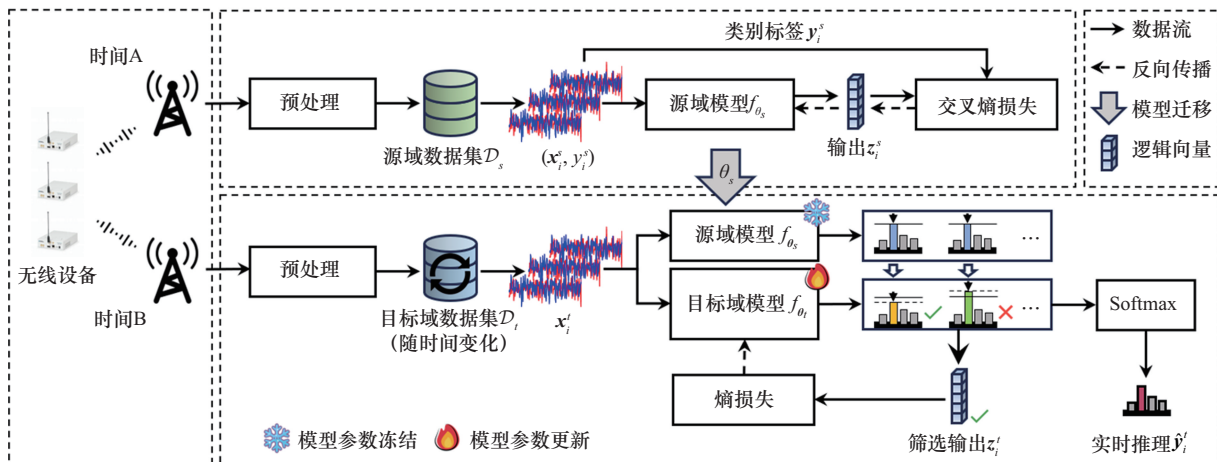


图3 本文方法整体架构




图4 CT-RFFNet结构

age pooling, AAP), 将不同长度的特征序列映射至固定维度, 从而聚合提取出的特征信息。

与传统 Inception 架构不同, CT-RFFNet 的设计在以下几个方面结合射频信号特性进行定制化改进。首先, 在卷积核尺度上, 参照 Xiao 等^[28]针对时间序列信号特征建模的相关结论, CT-RFFNet 采用较大尺寸卷积核 (卷积核大小为 39), 以增强对跨时间域长相关性的建模能力, 这对于捕获射频信号的长时依赖特征尤为关键。其次, 在多尺度特征聚合方面, CT-RFFNet 的 4 个 Inception 块通过逐层递进的方式堆叠, 并在每个块内融合不同尺度的卷积通道, 使模型能够同时兼顾局部纹理与全局时序模式。再次, 在鲁棒性优化上, CT-RFFNet 的头部块采用 AAP 与批归一化层的组合, 从而缓解不同采样长度和时间域抖动对特征提取带来的不确定性。最后, CT-RFFNet 与本文方法紧密结合, 实现特征提取与实时域适应的协同优化, 进一步提升跨时间 RFF 识别的泛化能力。

2.2.3 有监督预训练

有监督预训练在源域中进行, 其目的在于使模型从大量源域有标签信号样本中充分学习先验知识, 获取模型权重用于后续目标域模型的初始化。这里将从源域数据集 \mathcal{D}_s 中获取一个批次大小为 B 的训练数据记为 $(\mathbf{x}^s, \mathbf{y}^s)$ 。同时, 将 CT-RFFNet 建模为一个非线性映射函数 $f_{\theta_s}: \mathcal{X}_s \rightarrow \mathcal{Z}$, 其中 θ 为源域模型参数集合, \mathcal{X}_s 和 \mathcal{Z} 分别为源域样本空间和逻辑向量空间。模型输出可表示为

$$\mathbf{z}^s = f_{\theta_s}(\mathbf{x}^s) \quad (3)$$

其中, \mathbf{z}^s 为模型输出的逻辑向量。交叉熵损失是有监督分类任务中最常使用的损失函数, 其计算式为

$$\mathcal{L}_s = -\frac{1}{B} \sum_{i=0}^{B-1} \sum_{j=0}^{C-1} \hat{\mathbf{y}}_{ij}^s \text{lb} \sigma(\mathbf{z}_{ij}^s) \quad (4)$$

其中, C 为总类别数, $\sigma(\cdot)$ 表示 Softmax 函数, $\hat{\mathbf{y}}_i^s$ 为第 i 条样本对应真实类别标签的独热编码。具体而言, 若样本 i 属于第 c 类, 则构造长度为 C 的独热编码向量 $\hat{\mathbf{y}}_i^s \in \{0, 1\}^C$, 其中第 c 个分量为 1, 其余分量均为 0。计算出的交叉熵损失值用于反向传播更新模型参数, 最终充分训练后得到的预训练模型权重为 θ_s , 用于目标域模型初始化。

2.3 基于置信度差异的样本筛选

测试时自适应旨在借助测试样本构建优化目标, 实现测试阶段模型的同步实时域适应, 因此其自适应表现高度依赖于构建优化目标的测试样本质量。Lee 等^[29]证明基于熵的测试时自适应过程存在一种名为“集体智慧”的现象, 即模型在自适应过程中往往倾向于从大多数主导样本上坚持一种共性知识, 而忽略源于少数个体样本的“噪声”, 进而导致这些样本被误分类。同时, Lee 等^[29]提出置信度差异可以作为区分正确分类的主导样本与误分类的个体样本的充分指标, 并据此筛选出自适应后置信度上升的样本作为优化目标。

基于 Lee 等^[29]的研究, 本文提出一种不同的基于置信度差异的样本筛选机制, 即筛选出在测试时自适应过程中置信度下降的样本用于模型参数优化, 如图 3 所示。与 Lee 等^[29]解决的开放集识别任务不同的是, 在本文所针对的 RFF 识别任务中, 部分跨时间域下的样本往往因信道衰落和特征漂移导致模型预测置信度降低, 然而这类样本并非“噪声”样本, 而是携带了目标域中最具判别性的跨域差异信息的关键样本。若直接丢弃, 则会使模型忽略时变信道下最关键的知识差异; 相反, 若针对性地利用这些样本进行自适应优化, 可以促使模型调整原先的判别边界, 从而更好地捕获目标域的动态特征。

因此, 本文基于置信度差异筛选出代表关键知识差异的目标域样本用于测试时自适应优化, 同时

借助部分参数冻结策略（冻结除批归一化层以外的所有参数），最大化保留源域与目标域共性知识。首先定义筛选标准为

$$\Phi(\mathbf{z}_{i,c_0}^t, \tilde{\mathbf{z}}_{i,c_0}^t) = \mathbb{I}(\mathbf{z}_{i,c_0}^t \leq \tilde{\mathbf{z}}_{i,c_0}^t) \quad (5)$$

其中， \mathbf{z}_i^t 和 $\tilde{\mathbf{z}}_i^t$ 分别为第 i 条测试样本经冻结的源域模型和目标域自适应模型输出的逻辑向量， c_0 为源域模型的预测类别，因此 \mathbf{z}_{i,c_0}^t 和 $\tilde{\mathbf{z}}_{i,c_0}^t$ 分别为 \mathbf{z}_i^t 和 $\tilde{\mathbf{z}}_i^t$ 在类别 c_0 上的置信度， $\mathbb{I}(\cdot)$ 为指示函数，括号内条件满足时值为1，否则为0。最终，筛选出的代表样本进一步用于基于熵最小化的测试时自适应优化。

2.4 基于熵最小化的测试时自适应

2.4.1 熵最小化损失

基于筛选出的高质量测试样本，本节进一步引入基于熵最小化的测试时自适应方法。熵最小化在Wang等^[30]的工作中被首次提出来解决模型测试时自适应问题，并被广泛应用于图像分类、异常检测和检测任务。熵最小化旨在降低模型输出的混乱程度，迫使模型提升预测标签的置信度。将从目标域中获取的一批测试信号样本数据记为 \mathbf{x}^t ，同时将目标域自适应模型建模为一个非线性映射函数 $f_{\theta_i}: \mathcal{X}_i \rightarrow \mathcal{Z}$ ， \mathcal{X}_i 和 \mathcal{Z} 分别为目标域样本空间和逻辑向量空间。模型输出可表示为

$$\mathbf{z}^t = f_{\theta_i}(\mathbf{x}^t) \quad (6)$$

本文方法构建基于熵最小化的目标函数计算式为

$$\mathcal{L}_t(\mathbf{x}_i^t; \theta_i) = \Phi(\mathbf{z}_{i,c_0}^t, \tilde{\mathbf{z}}_{i,c_0}^t) \cdot H(\mathbf{z}_i^t) - \lambda \cdot H(\bar{\mathbf{z}}^t) \quad (7)$$

其中， θ_i 为目标域自适应模型参数集， $\bar{\mathbf{z}}^t = \frac{1}{N} \sum_{i=1}^N \mathbf{z}_i^t$ 为平均置信度向量， λ 为损失平衡因子， $-H(\bar{\mathbf{z}}^t)$ 项旨在防止模型对某个类别产生预测倾向，被广泛应用于文献[31-32]。 $H(\cdot)$ 为熵函数，其计算式为

$$H(p) = \sum_{k=1}^C p^k \text{lb} p^k \quad (8)$$

测试过程中，通过在筛选出的测试样本上计算熵损失 $\mathcal{L}_t(\mathbf{x}_i^t; \theta_i)$ ，进而更新目标域模型的批归一化层，实现模型的测试时自适应，同时获得模型对当前批次测试样本的实时推理结果。

2.4.2 测试时参数权重恢复

尽管测试时自适应范式能够有效提升域偏移场景下RFF识别的鲁棒性，但灾难性的源域知识遗忘是测试时自适应任务中的一个不可忽视的问题^[30]。

针对该问题，本文采用Wang等^[30]提出的策略，冻结CT-RFFNet中除BN层外的所有模型参数，同时使用当前批次数据的均值和方差进行批归一化，旨在充分保留源域及目标域间的共性知识，防止模型在自适应过程中产生灾难性知识遗忘。同时，在目标域模型初始化时，备份源域模型权重用于后续每个自适应步结束时，对当前自适应模型进行随机参数恢复，第 i 步自适应结束时恢复参数过程表示为

$$\theta_l^{i+1} = \mathbf{m}_l \odot \bar{\theta}_l + (1 - \mathbf{m}_l) \odot \theta_l^i \quad (9)$$

其中， θ_l^i 为第 l 个BN层的参数， $\bar{\theta}_l$ 为第 l 个BN层的备份权重， \mathbf{m}_l 为基于恢复率 γ 的权重掩码， \odot 为掩码操作。

3 实验与结果分析

3.1 实验参数及实验设置

3.1.1 数据集准备

本节在ORACLE^[33]和WiSig^[34]两个开源数据集上验证本文方法的有效性。ORACLE数据集采集于典型无线通信实验场景，其信号主要基于IEEE 802.11标准的Wi-Fi通信体制，具有明确的调制方式、稳定的系统参数配置以及可控的信道条件变化；WiSig数据集同样来源于实际无线通信系统，覆盖多种发射设备与传播环境，在设备差异性与信道多样性方面具有代表性。此外，上述两个数据集均已被广泛用于验证基于DL的射频指纹识别相关方法的特征建模、鲁棒性分析以及跨信道泛化性能评估^[35-37]。

ORACLE数据集信号采样率为5 Ms/s，带宽为56 kHz，选取了发射接收机距离分别为0.61、7.92、11.58和18.90 m的4个测试场景，每个测试场景包含两个采集于不同日期的子集 $\{S_1, S_2\}$ ，样本总类别数为16，每类包含400条样本，样本长度为6 000。WiSig数据集信号采样率为10 Ms/s，带宽为2.4 GHz，选取了4个采集于不同日期的子集 $\{\text{Day1}, \text{Day2}, \text{Day3}, \text{Day4}\}$ ，每个子集包含样本总类别数为6，每类样本量约为1 000条，样本长度为256。信号格式均为I/Q，源域预训练阶段训练和验证样本量比例为7:3，自适应阶段则使用目标域全部样本。

ORACLE数据集和WiSig数据集的I/Q数据振幅分布如图5和图6所示。在ORACLE数据集中，不同子集对应的数据振幅分布形态整体较一致，差

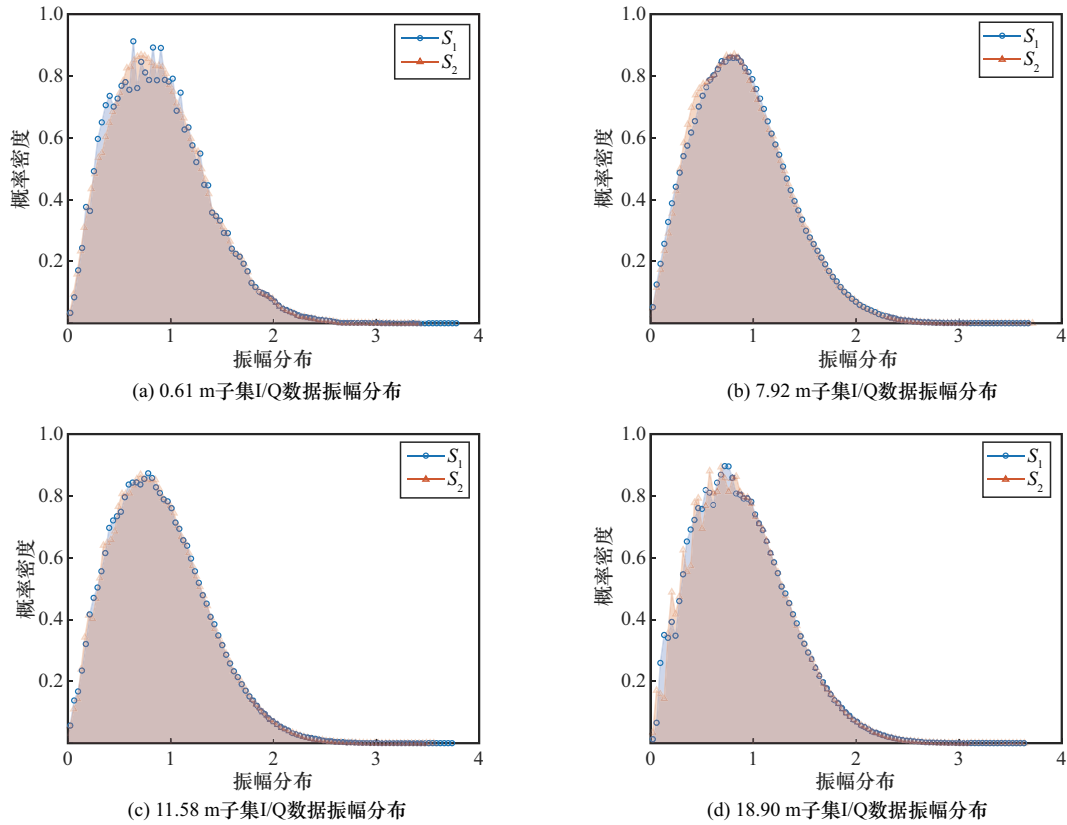


图 5 ORACLE数据集I/Q数据振幅分布

异主要存在于幅值尖峰处,表明其内部数据分布偏移程度相对较小;在WiSig数据集中,不同采集日期下的数据振幅分布在整体形态及局部细节上均存在较明显的差异,反映出其在时间维度上具有更显著的数据分布偏移特性。该分布特性的对比分析为后续方法在不同数据分布稳定性条件下的性能评估提供了直观的数据层面依据,有助于刻画实际场景中数据分布变化对模型泛化能力的影响。




图 6 WiSig数据集I/Q数据振幅分布

3.1.2 实验参数设置

在预训练过程中,将ORACLE和WiSig数据集总训练轮数分别设置为300和500,数据批次大小均设置为128,使用一个初始学习率为 1×10^{-3} 的Adam优化器结合余弦退火学习率自适应策略优化模型权重。在目标域自适应过程中,将数据批次大小均设置为64,仍选择Adam优化器,ORACLE和WiSig数据集自适应学习率均设置为 1×10^{-3} 。实验在配备有4块NVIDIA GeForce RTX 3090显卡的服务器上进行,使用的Python和Pytorch版本分别为3.8.0和2.4.1。

3.1.3 基线方法

为评估本文方法的有效性,在实验设置相同的前提下将多种跨域适应经典算法及最新算法进行对比,具体包括Ganin等^[38]提出的域对抗神经网络(domain-adversarial neural network, DANN)、Sun等^[39]提出的基于深度相关对齐损失的(DeepCORAL)算法、Zhang等^[40]提出的基于交叉匹配机制的UDA(cross-entropy matching based unsupervised domain adaptation, CMUDA)方法、Yang等^[41]提出的基于伪标签的跨接收机域适应(cross-

receiver domain adaptation, CRDA) 方法以及 Litrico 等^[18]提出的基于不确定性估计生成伪标签的自监督域适应 (UEPL) 方法。这些方法代表了对抗学习、统计分布对齐、半监督域适应、伪标签学习以及无监督损失重加权等不同类型的跨域泛化思路。

1) DANN: 基于对抗学习解决域适应问题的开创性工作, 被广泛用作域适应对比方法。

2) DeepCORAL: 基于域间相关特征对齐, 被广泛用作对比方法。

3) CMUDA: 借助数据增强构建基于伪标签的监督训练任务, 同时结合源域交叉熵损失。

4) CRDA: 一种结合伪标签及对抗训练的方法, 旨在解决跨接收机鲁棒射频指纹识别问题。

5) UEPL: 一种新颖的损失重加权策略, 以伪标签的可靠性为引导, 并结合对比式自监督学习框架, 用于解决从源空间到目标空间的 SFUDA 问题。

3.2 CT-RFFNet 性能评估

本节实验旨在通过基础泛化性能测试来评估 CT-RFFNet 在跨时间射频指纹识别任务中的有效性和优越性, 设置了 CT-RFFNet 与多个被广泛应用于 RFF 识别的骨干网络的对比分析, 具体包括经典的卷积神经网络 (convolutional neural network, CNN)^[42]、轻量级卷积神经网络 (light convolu-

tional neural network, LightCNN)^[43]、复值卷积神经网络 (complex-valued convolutional neural network, CVCNN)^[44]、残差神经网络 (residual neural network, ResNet)^[45]、时域卷积神经网络 (temporal convolutional network, TCN)^[46]。

具体而言, CT-RFFNet 及所有对比骨干网络首先在相同的源域场景下进行充分的预训练并保存模型权重, 然后使用保存的模型权重初始化目标域中相同的骨干网络模型, 在存在时间域分布偏移的目标域场景下直接测试识别准确率, 以评估网络的基础泛化性能。识别准确率定义为

$$P_{\text{Acc}} = \frac{\sum_{c=1}^{C_{\text{test}}} \text{TP}_c}{\sum_{c=1}^{C_{\text{test}}} (\text{TP}_c + \text{FP}_c)} \times 100\% \quad (10)$$

其中, TP_c 表示在第 c 个设备的测试数据中被正确识别为第 c 类的样本数, FP_c 表示在第 c 个设备的测试数据中被错误识别为其他类别的样本数。ORACLE 和 WiSig 数据集上骨干网络基础泛化性能对比如表 1 和表 2 所示, 其中, 加粗表示最优, 加下划线表示次优。

由表 1 和表 2 可知, 在不同的实验场景下, 本

表 1 ORACLE 数据集上骨干网络基础泛化性能对比

骨干网络	源域 → 目标域				平均
	0.61 m ($S_1 \rightarrow S_2$)	7.92 m ($S_1 \rightarrow S_2$)	11.58 m ($S_1 \rightarrow S_2$)	18.90 m ($S_1 \rightarrow S_2$)	
CNN	9.41%	3.94%	13.16%	40.20%	16.68%
LightCNN	40.48%	66.92%	72.75%	83.02%	65.79%
CVCNN	22.28%	22.75%	48.63%	64.64%	39.57%
ResNet	<u>57.55%</u>	74.89%	<u>73.31%</u>	86.20%	<u>72.99%</u>
TCN	26.78%	26.88%	61.02%	78.84%	48.38%
CT-RFFNet	81.09%	<u>73.06%</u>	79.44%	<u>85.70%</u>	79.82%

表 2 WiSig 数据集上骨干网络基础泛化性能对比

骨干网络	源域 → 目标域				平均
	Day1 → Other Days	Day2 → Other Days	Day3 → Other Days	Day4 → Other Days	
CNN	85.10%	79.99%	79.95%	92.04%	84.27%
LightCNN	82.78%	<u>87.45%</u>	71.98%	<u>95.24%</u>	84.36%
CVCNN	84.81%	89.07%	<u>81.58%</u>	91.94%	<u>86.85%</u>
ResNet	<u>91.33%</u>	81.03%	80.57%	96.59%	87.38%
TCN	78.41%	71.22%	68.12%	77.19%	73.73%
CT-RFFNet	94.07%	84.84%	82.35%	93.49%	88.69%

文所提出的 CT-RFFNet 均取得了出色的泛化表现。具体而言, ORACLE 数据集实验中设置了 4 个不同发射接收机距离场景, CT-RFFNet 在 0.61 m 和 11.58 m 场景下均取得了最高的识别准确率, 分别为 81.09% 和 79.44%, 尤其在 0.61 m 场景下, 比次优的 ResNet 提升超过 20%; 在 7.92 m 和 18.90 m 场景下, CT-RFFNet 性能有所下降但仍取得了次优的泛化表现。同时, CT-RFFNet 由于利用多尺度感受野机制提取射频指纹特征, 因此特征更具鲁棒性和稳定性, 这由平均识别准确率结果可以证明。在 WiSig 数据集上的实验中, CT-RFFNet 在 4 个场景中的两个取得了最高的识别准确率, 且在平均识别准确率上对比次优的 CVCNN 提升约 2%。

值得注意的是, CT-RFFNet 在取得更高的平均识别准确率的同时, 确实以增加模型参数量为代价。从图 7 可以看出, CT-RFFNet 对比其他基线模型而言是一个相对较为复杂的网络, 参数量较高表示其在实际应用部署中对硬件需求较高, 这源于 CT-RFFNet 中设置了较大尺度的卷积核以及多尺度特征提取架构, 但同时表明 CT-RFFNet 具有更强的记忆和存储性能, 保证了出色的鲁棒性和泛化能力, 因此本文认为这样的参数量和计算复杂度是可接受且必要的。

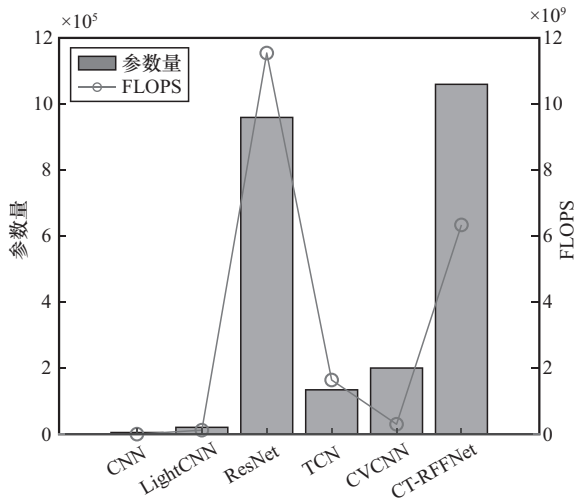


图 7 骨干网络参数量及每秒浮点运算次数(FLOPS)对比

3.3 域适应性能评估

3.3.1 超参数敏感性分析

本节评估了所提测试时自适应方法的识别准确率对不同超参数设置的敏感性, 通过改变关键超参数(包括模型参数权重恢复率、损失权重),

测试模型在不同配置下的识别准确率表现, 如图 8 所示。由图 8(a)可知, 随着恢复率的变化, 模型的识别准确率在 ORACLE 数据集上表现出较明显的波动, 特别是在较低的恢复率条件下, 这表明该数据集在跨时间场景下数据分布偏移较大, 当恢复率较低时, 模型容易在目标域数据上过拟合而产生源域知识遗忘, 随着恢复率升高, 识别准确率提升明显且在 $\gamma = 0.30$ 时达到最优, 表明模型参数权重恢复策略的有效性; 相比之下, WiSig 数据集上的识别准确率表现相对稳定, 在 $\gamma = 0.10$ 时达到最优。此外, 由图 8(b)可知, 损失权重的设置在两个数据集上对模型的鲁棒性产生的影响均较小, 表明本文方法对损失权重超参数敏感性较低。

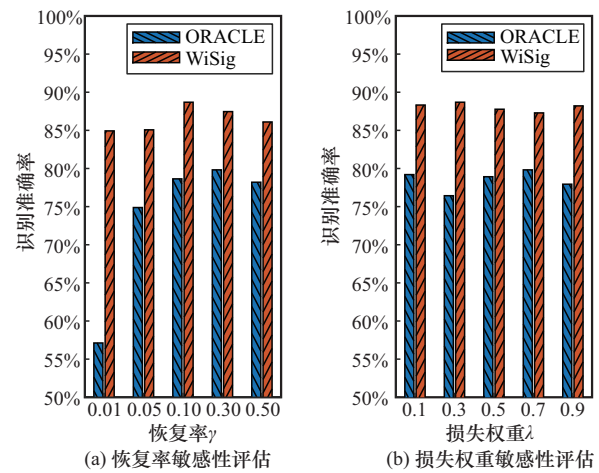


图 8 超参数敏感性评估

3.3.2 识别准确率对比

本节所有跨域自适应方法均使用相同的 CT-RFFNet 构建目标域模型, 并加载相同的源域预训练模型权重, 使用的目标域数据也完全相同。本文所研究的问题并非传统意义上经过多轮训练的标准域适应问题, 而是更贴合实际应用场景的实时性测试时自适应问题。其核心目标是模拟模型在目标域仅接触到测试数据且必须即时作出决策的实际场景, 因此在对本文方法的识别准确率测试实验中, 设置自适应步长为 1, 即进行单步测试时自适应, 以评估其应对高动态实时性强的真实场景的有效性。同时, 为保证实验的公平性, 本文在对比实验中也将会将现有方法的训练轮数统一设置为 1, 以保持实验条件与测试时自适应的一致性, ORACLE 和 WiSig 数据集上不同方法的单步域适应识别准确率测试结果如表 3 和表 4 所示。

表 3 ORACLE 数据集上不同方法的单步域适应识别准确率对比

方法	源域 → 目标域				平均
	0.61 m ($S_1 \rightarrow S_2$)	7.92 m ($S_1 \rightarrow S_2$)	11.58 m ($S_1 \rightarrow S_2$)	18.90 m ($S_1 \rightarrow S_2$)	
直接测试	81.09%	73.06%	79.44%	<u>85.70%</u>	79.82%
DANN ^[38]	60.97%	65.50%	88.11%	72.44%	71.75%
DeepCORAL ^[39]	74.72%	78.19%	<u>89.42%</u>	85.02%	81.84%
CMUDA ^[40]	77.33%	79.16%	88.75%	76.94%	80.54%
CRDA ^[41]	85.39%	<u>81.06%</u>	84.92%	84.45%	<u>83.96%</u>
UEPL ^[18]	72.81%	82.14%	86.07%	82.32%	80.84%
CT-RFFNet	<u>84.97%</u>	79.67%	90.06%	86.30%	85.25%

表 4 WiSig 数据集上不同方法的单步域适应识别准确率对比

方法	源域 → 目标域				平均
	Day1 → Other Days	Day2 → Other Days	Day3 → Other Days	Day4 → Other Days	
直接测试	94.07%	84.84%	82.35%	93.49%	88.69%
DANN ^[38]	34.13%	42.60%	43.92%	38.28%	39.73%
DeepCORAL ^[39]	<u>95.64%</u>	<u>99.01%</u>	95.82%	97.34%	<u>96.95%</u>
CMUDA ^[40]	61.74%	80.61%	62.49%	88.94%	73.45%
CRDA ^[41]	43.22%	66.33%	82.42%	57.90%	62.47%
UEPL ^[18]	77.91%	82.19%	80.60%	86.24%	81.74%
CT-RFFNet	99.49%	99.40%	<u>92.54%</u>	<u>96.98%</u>	97.10%

通过 ORACLE 数据集上的实验结果对比可以发现, 经过单步测试时自适应, 本文方法对比源域预训练模型直接测试的识别准确率提升达到 5% 左右; 在 WiSig 数据集上, 本文方法对比直接测试也存在接近 10% 的识别准确率提升。在 ORACLE 数据集上, 本文方法在 4 个场景下的平均识别准确率明显高于基线方法, 比次优的 CRDA 提升 1% 左右; 在 WiSig 数据集上, 本文方法在 4 个场景下的平均识别准确率也高于所有基线方法。这一现象表明, 本文方法能够有效帮助射频指纹识别模型适应存在跨时间域数据分布偏移的目标域, 提升测试识别准确率。尽管 CRDA 在 ORACLE 数据集上取得了相对优异的性能, 但该方法建立在生成伪标签具有较高可靠性的假设之上。在早期迭代阶段, 由于目标域样本特征尚未充分对齐, 伪标签往往存在偏差。尽管该方法引入了类别权重校正策略以缓解误差传播, 但当源域与目标域信号分布差异较大时, 错误的伪标签仍可能逐步累积并传递, 从而使模型陷入次优收敛状态。这一点在源域与目标域差异显著的 WiSig 数据集上的实验结果中得到了验证。相比之下, Deep-

CORAL 在 WiSig 数据集上虽表现相对稳定, 但仅取得次优结果, 原因在于该方法主要通过约束整体特征统计量来缩小全局分布差异, 而未显式考虑各类别在源域与目标域间的分布一致性, 因而导致性能存在不稳定性。

3.3.3 混淆矩阵分析

本文方法在 ORACLE 数据集上两个不同发射接收机距离场景下 (0.61 m 及 7.92 m) 的真实类别与预测类别混淆矩阵如图 9 所示。从图 9 可以看出, 本文方法能够有效帮助射频指纹识别模型克服跨时间域数据分布偏移带来的性能下降, 使模型学习源域与目标域之间的知识差异并对受到域偏移影响的射频指纹进行补偿修正, 提升识别准确率, 如 0.61 m 预测类别 4、7.92 m 预测类别 11 和预测类别 2。然而, 由混淆矩阵结果发现, 本文方法针对某些预测类别并不总是有效的, 如 0.61 m 预测类别 5 和预测类别 6。原因首先在于, 模型在源域预训练过程中未能有效学习到关于该类别的先验知识, 或者该类别的源域与目标域之间数据分布偏移过大, 导致目标域自适应过程中模型无法进一步学习和分析源域

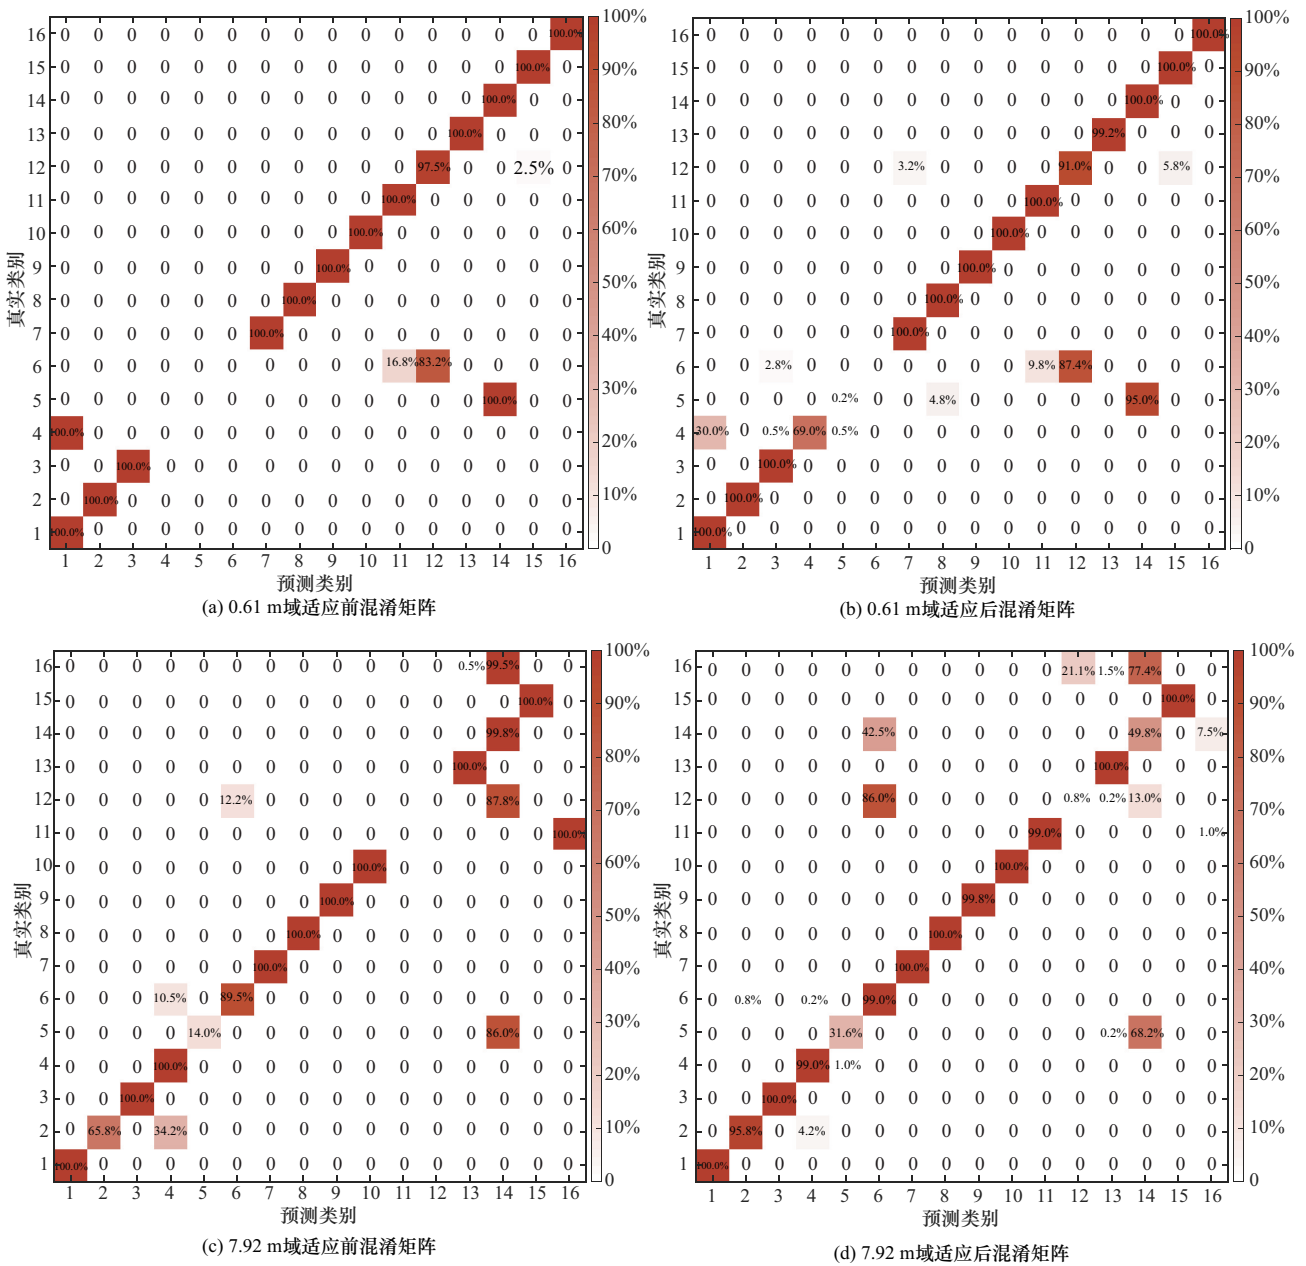


图 9 ORACLE数据集上真实类别与预测类别混淆矩阵

与目标域之间的分布差异。因此，针对该类别的识别性能无法获得明显提升，需要借助更高效的源域预训练策略使得模型学习更高质量的先验知识并提取更鲁棒的射频指纹特征。由于本文侧重解决模型跨时间域自适应问题，针对源域预训练方法不再赘述。

此外，在某些类别中（如 7.92 m 预测类别 14 及预测类别 11），信号特征在源域和目标域的分布差异可能较为复杂，尤其是受环境噪声和信号传播的影响，模型在源域中学到的特征难以直接迁移到

目标域，甚至导致特征损坏。特别是在频谱特性和时域特性方面，这些差异未能在源域预训练阶段有效捕获，导致在目标域中的适应性较差。

3.3.4 单步域适应耗时对比

本节实验旨在对比本文方法以及所有对比方法的单步域适应耗时，以验证本文方法在实时性方面是否具有优势。不同方法单步域适应耗时对比如表 5 所示。由实验结果可知，本文方法相较于其他对比方法的单步域适应耗时具有明显优势，能够更有效地应对实时域适应任务。

表 5 不同方法单步域适应耗时对比

方法	ORACLE 数据集 0.61 m/s	WiSig 数据集 Day1/s
DANN ^[38]	28.48	1.87
DeepCORAL ^[39]	28.04	1.71
CMUDA ^[40]	33.78	1.92
CRDA ^[41]	22.38	1.71
UEPL ^[18]	45.16	2.52
本文方法	16.93	1.20

3.4 消融实验

本节实验旨在验证本文方法中基于置信度的样本筛选机制以及部分参数冻结策略的有效性，同时对比了本文提出的筛选机制与 Lee 等^[29]提出的筛选机制间的性能差异，ORACLE 和 WiSig 数据集上消融实验识别准确率对比如表 6 和表 7 所示。

由表 6 和表 7 可知，本文方法在几乎所有场景下均取得了最高的识别准确率。在“仅熵损失”实验中，未设置样本筛选机制，即所有测试样本全部用于自适应训练，对比本文方法平均识别准确率在两个数据集上均降低约 0.5%，充分证明本文提出的样本筛选机制的有效性。在模型参数“不冻结”测试实验中，模型所有参数均可被优化器更新，与本文方法对比可得出结论，冻结部分参数具有显著优势，原因在于冻结参数能够充分保留源域知识，避免测试时自适应过程中灾难性的知识遗忘。文献^[29]

提出的样本筛选机制如 1.2 节所述，对比本文提出的基于置信度的样本筛选机制，平均识别准确率也有所降低。实验结果可以证明，本文提出的基于置信度的样本筛选机制和参数冻结策略与熵最小化损失结合后，能够有效提升模型跨时间域自适应性能。

4 结束语

针对跨时间域射频指纹识别中由信道与环境变化引起的数据分布偏移问题，本文研究了在缺乏目标域标注信息条件下提升模型稳定性与泛化能力的有效途径，并提出了一种面向跨域泛化的 RFF 识别测试时自适应方法。该方法通过置信度差异样本筛选与熵最小化策略，有效提升了模型对目标域的自适应能力。针对跨时间域识别中鲁棒特征提取的问题，本文设计了 CT-RFFNet，利用多尺度卷积提取特征。实验结果表明，该网络在多个典型数据集上均优于现有主流骨干网络，在基础泛化性能上具有显著优势。本文在 ORACLE 与 WiSig 数据集上进行了测试，结果表明，所提方法在保持较高识别准确率的同时显著降低了自适应过程的耗时，兼顾了准确性与实时性，满足了非合作通信环境下的实际应用需求。此外，通过消融实验验证了置信度样本筛选机制与参数冻结策略在测试时自适应中的关键作用，进一步说明了本文方法各模块设计的合理性和有效性。尽管本文方法在性能与效率方面均取得了

表 6 ORACLE 数据集上消融实验识别准确率对比

骨干网络	源域 → 目标域				平均
	0.61 m ($S_1 \rightarrow S_2$)	7.92 m ($S_1 \rightarrow S_2$)	11.58 m ($S_1 \rightarrow S_2$)	18.90 m ($S_1 \rightarrow S_2$)	
仅熵损失	84.69%	78.58%	89.97%	86.34%	84.89%
不冻结	81.34%	74.78%	86.80%	75.25%	79.54%
文献 ^[29]	84.09%	78.58%	89.98%	86.38%	84.76%
本文方法	84.97%	79.67%	90.06%	86.30%	85.25%

表 7 WiSig 数据集上消融实验识别准确率对比

骨干网络	源域 → 目标域				平均
	Day1 → Other Days	Day2 → Other Days	Day3 → Other Days	Day4 → Other Days	
仅熵损失	99.48%	99.40%	90.51%	96.99%	96.60%
不冻结	99.26%	88.50%	74.32%	77.23%	84.83%
文献 ^[29]	99.46%	99.31%	90.41%	96.80%	96.49%
本文方法	99.49%	99.40%	92.54%	96.98%	97.10%

良好效果,但在提升预训练质量、引入多模态信息融合等方面仍具有进一步研究的空间,这将作为未来的研究方向。

参考文献:

- [1] Ahvanooy M T, Zhu M X, Li Q M, et al. Modern authentication schemes in smartphones and IoT devices: an empirical survey[J]. *IEEE Internet of Things Journal*, 2022, 9(10): 7639-7663.
- [2] Zhang J Q, Li G Y, Marshall A, et al. A new frontier for IoT security emerging from three decades of key generation relying on wireless channels[J]. *IEEE Access*, 2020, 8: 138406-138446.
- [3] 桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术: 机遇与挑战[J]. *通信学报*, 2019, 40(2): 19-23
Gui G, Wang Y, Huang H. Deep learning based physical layer wireless communication techniques: opportunities and challenges[J]. *Journal on Communications*, 2019, 40(2): 19-23.
- [4] Zeng Y, Gong Y, Liu J W, et al. Multi-channel attentive feature fusion for radio frequency fingerprinting[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(5): 4243-4254.
- [5] He B X, Wang F G. Anti-modulation-classification transmitter design against deep learning approaches[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(7): 6808-6823.
- [6] Shen G X, Zhang J Q, Wang X Y, et al. Federated radio frequency fingerprint identification powered by unsupervised contrastive learning[J]. *IEEE Transactions on Information Forensics and Security*, 2024, 19: 9204-9215.
- [7] 李英凯, 王淑菲, 张逸彬, 等. 基于信号特征知识图谱和特征融合的特定制射源识别技术[J]. *移动通信*, 2023, 47(6): 115-121.
Li Y K, Wang S F, Zhang Y B, et al. Specific emitter identification technology based on signal feature knowledge graph and feature fusion[J]. *Mobile Communications*, 2023, 47(6): 115-121.
- [8] Zhang J Q, 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.
- [9] 张茜茜, 王禹, 林云, 等. 基于深度学习的自动调制识别方法综述[J]. *无线电通信技术*, 2022, 48(4): 697-710.
Zhang X X, Wang Y, Lin Y, et al. A comprehensive survey of deep learning-based automatic modulation recognition methods[J]. *Radio Communications Technology*, 2022, 48(4): 697-710.
- [10] 闫高丽, 付雪, 王禹, 等. 面向射频指纹信号分析与智能识别的研究综述[J]. *南通大学学报(自然科学版)*, 2025, 24(2): 1-21.
Yan G L, Fu X, Wang Y, et al. A survey on radio frequency fingerprint signal analysis and intelligent identification[J]. *Journal of Nantong University (Natural Science Edition)*, 2025, 24(2): 1-21.
- [11] 桂冠, 陶梦圆, 王诚, 等. 面向特定制射源识别的小样本学习方法综述[J]. *南通大学学报(自然科学版)*, 2023, 22(3): 1-16.
Gui G, Tao M Y, Wang C, et al. Survey of few-shot learning methods for specific emitter identification[J]. *Journal of Nantong University (Natural Science Edition)*, 2023, 22(3): 1-16.
- [12] Cai Z X, Wang Y, Gui G, et al. Toward robust radio frequency fingerprint identification via adaptive semantic augmentation[J]. *IEEE Transactions on Information Forensics and Security*, 2025, 20: 1037-1048.
- [13] Peng L N, Peng H C, Fu H, et al. Channel-robust radio frequency fingerprint identification for cellular uplink LTE devices[J]. *IEEE Internet of Things Journal*, 2024, 11(10): 17154-17169.
- [14] Qi X Y, Hu A Q, Zhang Z. Data-and-channel-independent radio frequency fingerprint extraction for LTE-V2X[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2024, 10(3): 905-919.
- [15] Peng Y, Liu P F, Zhang Q Y, et al. Dynamic adaptation RFF identification method leveraging cognitive representation learning[J]. *IEEE Transactions on Information Forensics and Security*, 2024, 19: 7939-7951.
- [16] Chen J, Wong W K, Hamdaoui B. Unsupervised contrastive learning for robust RF device fingerprinting under time-domain shift[J]. *arXiv Preprint, arXiv: 2403.04036*, 2024.
- [17] Fang Y Q, Yap P T, Lin W L, et al. Source-free unsupervised domain adaptation: a survey[J]. *arXiv Preprint, arXiv: 2301.00265*, 2023.
- [18] Litrico M, Del Bue A, Morerio P. Guiding pseudo-labels with uncertainty estimation for source-free unsupervised domain adaptation[C]// *Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2023: 7640-7650.
- [19] Li J J, Yu Z Q, Du Z K, et al. A comprehensive survey on source-free domain adaptation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(8): 5743-5762.
- [20] Li R, Jiao Q F, Cao W M, et al. Model adaptation: unsupervised domain adaptation without source data[C]// *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2020: 9638-9647.
- [21] Li K L, Bao J Z, Xie X, et al. Receiver-agnostic radio frequency fingerprint identification for zero-trust wireless networks[J]. *IEEE Journal on Selected Areas in Communications*, 2025, 43(6): 1981-1997.
- [22] Wan H, Wang Q, Fu X, et al. VC-SEI: robust variable-channel specific emitter identification method using semi-supervised domain adaptation[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(12): 18228-18239.
- [23] Xie L N, Peng L N, Zhang J Q. Towards robust RF fingerprint identification using spectral regrowth and carrier frequency offset[C]// *Proceedings of the IEEE INFOCOM 2025 - IEEE Conference on Computer Communications*. Piscataway: IEEE Press, 2025: 1-10.
- [24] Jang D, Lee S, Choi G, et al. Energy-based domain adaptation without intermediate domain dataset for foggy scene segmentation[J]. *IEEE Transactions on Image Processing*, 2024, 33: 6143-6157.
- [25] Yuan Y G, Xu B B, Hou L, et al. TEA: test-time energy adaptation[C]// *Proceedings of the 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2024: 23901-23911.
- [26] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]// *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2015: 1-9.
- [27] Fawaz H I, Lucas B, Forestier G, et al. InceptionTime: finding AlexNet for time series classification[J]. *arXiv Preprint, arXiv:1909.04939*, 2019.
- [28] Xiao Q, Wu B Q, Zhang Y, et al. Dynamic sparse network for time series classification: learning what to "see" [J]. *arXiv Preprint, arXiv: 2212.09840*, 2022.
- [29] Lee J, Das D, Choo J, et al. Towards open-set test-time adaptation uti-

- lizing the wisdom of crowds in entropy minimization[C]//Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2024: 16334.
- [30] Wang D Q, Shelhamer E, Liu S T, et al. Tent: fully test-time adaptation by entropy minimization[J]. arXiv Preprint, arXiv: 2006.10726, 2020.
- [31] Lim H, Kim B, Choo J, et al. TTN: a domain-shift aware batch normalization in test-time adaptation[J]. arXiv Preprint, arXiv: 2302.05155, 2023.
- [32] Liu W T, Wang X Y, Owens J D, et al. Energy-based out-of-distribution detection[J]. arXiv Preprint, arXiv: 2010.03759, 2020.
- [33] Sankhe K, Belgiovine M, Zhou F, et al. ORACLE: optimized radio classification through convolutional neural networks[C]//Proceedings of the IEEE INFOCOM 2019 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2019: 370-378.
- [34] Hanna S, Karunaratne S, Cabric D. WiSig: a large-scale WiFi signal dataset for receiver and channel agnostic RF fingerprinting[J]. IEEE Access, 2022, 10: 22808-22818.
- [35] Wang T C, Yu L, Wang W Y, et al. Specific emitter identification based on the multi-discrepancy deep adaptation network[J]. IET Radar, Sonar & Navigation, 2022, 16(12): 2079-2088.
- [36] Wang Y, Ohtsuki T, Sun Z, et al. Avoiding shortcuts: enhancing channel-robust specific emitter identification via single-source domain generalization[J]. IEEE Transactions on Wireless Communications, 2025, 24(4): 3163-3176.
- [37] He J S, Huang S, Yang Z, et al. Channel-agnostic radio frequency fingerprint identification using spectral quotient constellation errors[J]. IEEE Transactions on Wireless Communications, 2024, 23(1): 158-170.
- [38] Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation[J]. arXiv Preprint, arXiv: 1409.7595, 2014.
- [39] Sun B C, Saenko K. Deep CORAL: correlation alignment for deep domain adaptation[J]. arXiv Preprint, arXiv: 1607.01719, 2016.
- [40] Zhang B B, Zhang D H, Li Y D, et al. Unsupervised domain adaptation for RF-based gesture recognition[J]. IEEE Internet of Things Journal, 2023, 10(23): 21026-21038.
- [41] Yang L, Li Q, Ren X Y, et al. Mitigating receiver impact on radio frequency fingerprint identification via domain adaptation[J]. IEEE Internet of Things Journal, 2024, 11(13): 24024-24034.
- [42] Merchant K, Revay S, Stantchev G, et al. Deep learning for RF device fingerprinting in cognitive communication networks[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 160-167.
- [43] Qing G W, Wang H F, Zhang T P. Radio frequency fingerprinting identification for Zigbee via lightweight CNN[J]. Physical Communication, 2021, 44: 101250.
- [44] Wang Y, Gui G, Gacanin H, et al. An efficient specific emitter identification method based on complex-valued neural networks and network compression[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2305-2317.
- [45] Jian T, Rendon B C, Ojuba E, et al. Deep learning for RF fingerprinting: a massive experimental study[J]. IEEE Internet of Things Magazine, 2020, 3(1): 50-57.
- [46] Zhu C Y, Liu L, Peng X Y. Specific emitter identification based on temporal convolutional network sequence processing[J]. IEEE Communications Letters, 2023, 27(10): 2667-2671.

[作者简介]



张杰 (2001-), 男, 江苏南通人, 南京邮电大学博士生, 主要研究方向为深度学习、特定辐射源识别、自动调制识别。



王琴 (1988-), 女, 河南周口人, 南京邮电大学副研究员, 主要研究方向为低空智联网络、频谱认知与优化共享、资源智能定价、博弈论、区块链等。



尹悦 (1996-), 女, 江苏盐城人, 日本庆应义塾大学助理教授, 主要研究方向为无人机通信、6G通信资源分配、语义通信等。



王禹 (1996-), 男, 江苏盐城人, 南京邮电大学教授, 主要研究方向为深度学习、优化及其在无线通信中的应用等。



桂冠 (1982-), 男, 安徽铜陵人, 南京邮电大学教授、博士生导师, 主要研究方向为人工智能、深度学习、计算机视觉、大语言模型、具身智能、电磁频谱认知、智能信号处理、智能无线通信等。