

# 扩散模型驱动的跨时间域 通信辐射源个体增量识别方法

赵东兴<sup>1</sup>, 刘 辉<sup>1</sup>, 黄科举<sup>1,2\*</sup>, 杨俊安<sup>1</sup>

(1. 国防科技大学电子对抗学院电子对抗工程系, 安徽合肥 230000; 2. 安徽省电子制约技术重点实验室, 安徽合肥 230000)

**摘 要:** 通信辐射源个体识别(Specific Emitter Identification, SEI)利用信号发射设备由于制造误差与器件老化等因素形成的细微硬件差异,在物理层完成身份区分与溯源. 相较依赖协议与密钥的传统认证方式,它无需改动协议栈,对业务内容透明且部署成本低,已在频谱监管、无线安全、认知无线电与复杂电磁环境感知等场景展现重要价值. 然而在真实无线环境中,跨时间与跨场景的信道变化会对射频指纹产生不稳定的调制与失真:多径衰落、频偏与相位噪声随时间漂移,使同一设备在不同时刻的信号表现差异显著,识别性能在目标域显著退化,成为落地应用的核心障碍. 为缓解域间分布偏移,现有研究主要从迁移学习与领域自适应展开. 迁移学习依赖目标域标注进行微调,虽可提升目标域性能,但易破坏源域已学知识并诱发灾难性遗忘;无监督领域自适应通过特征对齐、伪标签与熵最小化缩小分布差异,但因缺乏显式监督,提升幅度受限,且难以应对数据持续到来的在线场景. 增量学习强调在不断接收新数据时兼顾“适应—记忆”的平衡,但多数方法仍需标注或额外存储,难以直接用于无线信号的无标注跨时间应用. 生成式建模的发展为解决该问题提供了新契机. 扩散模型以正向加噪、反向去噪的机制刻画复杂分布,具备建模“信道扰动—设备本征特征”叠加关系、从观测中恢复指纹的潜力,但既有工作多聚焦去噪或数据生成,尚未兼顾跨时间域识别与持续学习需求. 为此,本文提出一种扩散模型驱动的跨时间域通信辐射源个体增量识别方法:在源域阶段以正向扩散显式建模信道扰动,在目标域通过反向扩散逐步恢复接近源域分布的判别性表示,以抑制特征漂移;在扩散网络中引入跨注意力,将个体信息注入去噪过程以增强类间可分性;进一步结合无监督增量学习,通过分布一致性与知识保持正则,仅依赖无标注目标样本实现持续自适应,并有效缓解遗忘. 在 WiSig 数据集上,跨时间个体识别实验表明,所提方法在目标域识别准确率较典型领域自适应方法提升超过 5 个百分点,在源域性能保持方面较主流增量学习策略提升约 10 个百分点,验证了其信道还原与特征对齐能力,并体现出在动态信道条件下的鲁棒性与实用价值.

**关键词:** 通信辐射源个体识别;跨时间域;扩散模型;增量学习;信号处理;跨注意力机制

**基金项目:** 国防科技大学青年自主创新科学基金(No.ZK24-44)

**中图分类号:** TN911.7 **文献标识码:** A **文章编号:** 0372-2112(2025)12-4527-14

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20250843

## A Diffusion Model Driven Approach for Cross-Time-Domain Incremental Specific Emitter Identification

ZHAO Dong-xing<sup>1</sup>, LIU Hui<sup>1</sup>, HUANG Ke-ju<sup>1,2\*</sup>, YANG Jun-an<sup>1</sup>

(1. Department of Electronic Countermeasures, College of Electronic Engineering, National University of Defense Technology, Hefei, Anhui 230000, China; 2. Anhui Province Key Laboratory of Electronic Restriction, Hefei, Anhui 230000, China)

**Abstract:** Specific emitter identification (SEI) exploits subtle hardware discrepancies caused by manufacturing imperfections and device aging to perform transmitter identification and attribution at the physical layer. Compared with traditional authentication schemes that rely on protocols and cryptographic keys, SEI requires no modification to the protocol stack, is transparent to transmitted data, and incurs low deployment cost, making it valuable for applications such as spectrum regulation, wireless security, cognitive radio, and sensing in complex electromagnetic environments. However, in real-world wireless scenarios, time-varying and scene-dependent channel conditions introduce unstable modulation and distortion to radio-frequency fingerprints. Effects such as multipath fading, carrier frequency offset, and phase noise drift over

time, causing the signals emitted by the same device to exhibit significant temporal variation. As a result, identification performance degrades markedly in the target domain, posing a major obstacle to practical deployment. To mitigate domain distribution shifts, existing studies mainly investigate transfer learning and domain adaptation approaches. Transfer learning relies on fine-tuning with labeled target-domain data and can improve target-domain performance, but it often disrupts previously learned source-domain knowledge and leads to catastrophic forgetting. Unsupervised domain adaptation reduces distribution discrepancies through feature alignment, pseudo labeling, and entropy minimization; however, due to the absence of explicit supervision, performance improvements are limited, and such methods struggle to handle continuously arriving data in online scenarios. Incremental learning emphasizes balancing adaptation to new data with the preservation of prior knowledge, yet most existing approaches still require labeled data or additional storage, making them difficult to apply directly to unlabeled cross-time SEI tasks. The advancement of generative modeling provides a new opportunity to address these challenges. Diffusion models characterize complex data distributions through forward noise injection and reverse denoising processes, and are well suited for modeling the superposition of channel perturbations and device-intrinsic features, enabling the recovery of radio-frequency fingerprints from distorted observations. Nevertheless, existing studies predominantly focus on denoising or data generation, and have not fully addressed cross-time identification and continual learning requirements. To this end, this paper proposes a diffusion-model-driven cross-time incremental SEI method. In the source domain, forward diffusion is employed to explicitly model channel perturbations, while in the target domain, reverse diffusion progressively restores discriminative representations that approximate the source-domain distribution, thereby suppressing feature drift. A cross-attention mechanism is incorporated into the diffusion network to inject emitter identity information during denoising, enhancing inter-class separability. Furthermore, an unsupervised incremental learning strategy is introduced, which achieves continual adaptation using only unlabeled target-domain samples through distribution consistency and knowledge-preservation regularization, effectively mitigating catastrophic forgetting. Cross-time identification experiments on the WiSig dataset demonstrate that the proposed method improves target-domain identification accuracy by more than 5 percentage points compared with representative domain adaptation methods, and enhances source-domain performance retention by approximately 10 percentage points relative to mainstream incremental learning strategies, validating its channel restoration capability, feature alignment effectiveness, and robustness under dynamic channel conditions.

**Key words:** specific emitter identification; cross-time domain; diffusion model; incremental learning; signal processing; cross-attention mechanism

**Foundation Item(s):** Independent Scientific Research Program of National University of Defense Technology (No.ZK24-44)

## 1 引言

通信辐射源个体识别(Specific Emitter Identification, SEI), 又称射频指纹识别(Radio Frequency Fingerprint Identification, RFFI), 是一种利用无线发射设备在制造过程中因硬件微小差异而形成的独特射频指纹特征, 实现发射端身份区分与识别的关键技术<sup>[1]</sup>. 与依赖高层协议的传统认证方式相比, SEI工作在物理层, 能够直接基于接收的无线信号完成识别, 具有部署成本低、无需修改协议栈、对通信内容透明等优势, 因此在认知无线电、频谱监测、通信干扰溯源以及复杂电磁环境感知等领域具有广阔的应用前景<sup>[2,3]</sup>.

然而, SEI在实际无线通信环境中面临显著挑战. 特别是在跨时间、跨场景的信道条件变化下, 信道的时变特性会对设备的射频指纹特征产生不稳定的调制与失真, 导致同一设备在不同时刻、不同地点的信号表现出较大的差异<sup>[4]</sup>. 这种信道引入的特征漂移不仅可能掩盖设备固有的差异性, 还会增加不同设备指纹特征间的相似性, 从而降低SEI系统的鲁棒性与泛化能力, 对长期稳定识别带来了严峻挑战<sup>[5]</sup>.

为应对复杂信道环境带来的挑战, 近年来研究人员提出了多种跨领域SEI方法, 主要可分为迁移学习和领域自适应两类. 迁移学习方法通过利用源域训练中获得的知识, 并在目标域上进行再训练, 从而在目标域获得较高的识别准确率, 代表性技术包括参数微调<sup>[6]</sup>、相似性度量<sup>[7]</sup>和张量分解<sup>[8]</sup>等. 然而, 此类方法通常依赖于目标域的有标注样本, 并且在适应目标域的过程中容易导致源域性能显著下降. 相比之下, 领域自适应方法旨在通过特征对齐等技术缩小源域与目标域之间的分布差异, 在无需目标域标注样本的情况下提升目标域识别性能. 代表性技术包括权重共享<sup>[9]</sup>、伪标签<sup>[10]</sup>和熵最小化<sup>[11]</sup>等. 但由于缺乏显式的标签信息, 其在目标域上的性能提升仍然有限. 更为重要的是, 上述两类方法均未考虑增量学习场景, 即模型缺乏持续学习与适应动态环境的能力.

增量学习(Incremental Learning, IL)是一种通过持续更新已有模型来适应新数据的方法. 在实际应用中, 增量学习要求模型在接收到新数据时既能保持已学知识, 又能适应数据分布的变化. 然而, 传统的增量学习

方法通常依赖目标域的标注数据,这在实际无线信号场景中难以满足.典型的增量学习策略包括知识蒸馏(Knowledge Distillation, KD)<sup>[12]</sup>、参数正则化(Elastic Weight Consolidation, EWC)<sup>[13]</sup>以及经验回放(Experience Replay, ER)<sup>[14]</sup>等.针对这一问题,本文提出了一种基于无标注数据的增量学习方法,用于实现通信辐射源个体的跨时间域识别,以应对复杂的动态信道条件.值得指出的是,增量学习与元学习(Meta-Learning)<sup>[15]</sup>在目标与机制上存在本质差异.元学习旨在通过学习多个任务之间的共享知识,使模型能够快速适应新任务;而增量学习则侧重于在任务或数据逐步到来的过程中,保持模型性能的稳定与持续更新能力.与元学习不同,本文提出的增量学习框架无需大量标注样本或任务级再训练,能够仅依赖无标注的目标域数据实现对动态信道环境的自适应更新,因而具有更高的实用性与可扩展性.

随着生成模型的发展,特别是扩散模型在图像去噪<sup>[16]</sup>、恢复<sup>[17]</sup>和合成<sup>[18]</sup>等领域取得了显著进展.扩散模型以其强大的分布建模与去噪能力著称,近年来已被逐步引入信号处理与SEI任务<sup>[19]</sup>.已有研究表明,扩散模型在复杂信道条件下的SEI应用中展现出巨大潜力,尤其在信号去噪<sup>[20]</sup>和数据生成<sup>[21]</sup>等方面表现突出.然而,这些方法在图像领域的成功往往伴随着较高的时间和计算资源消耗,这一缺点在相关文献中已有详细讨论.尽管潜空间扩散模型(Latent Diffusion Models, LDM)<sup>[22]</sup>尝试通过改进计算效率来缓解这一问题,

但其对样本长度的限制(尤其当信号长度仅为256时)使其无法适用于本文的任务.

为解决跨天环境下通信辐射源个体识别的鲁棒性问题,本文提出了一种扩散模型驱动的跨时间域个体增量识别方法.该方法首先利用源域数据训练扩散模型以建模和恢复信道特性,并在扩散过程中引入跨注意力机制,将设备个体信息嵌入到信号恢复与生成中,从而有效保持特征区分性;随后在增量学习阶段,仅依赖无标注的目标域样本对模型进行持续更新,实现对动态信道条件的自适应并赋予模型持续学习能力.与图像领域的扩散模型相比,本文方法不仅成功解决了时变信道带来的信号差异问题,还显著提升了目标域识别的准确率.在公开WiSig<sup>[23]</sup>数据集上的实验结果表明,与典型领域自适应方法相比,本文方法在目标域识别准确率上提升超过5%,同时在源域性能保持方面较现有增量学习方法提升约10%,验证了该方法在复杂动态环境下的有效性与应用价值.

## 2 问题描述和相关研究

### 2.1 问题描述

#### 2.1.1 跨时间域通信辐射源个体识别框架

本文提出了一种扩散模型驱动的跨时间域通信辐射源个体增量识别方法,旨在解决跨天环境下信道变化显著、目标域缺乏标注数据以及模型缺乏持续学习能力等问题.整体流程如图1所示,主要由四个关键模块组成:数据采集、样本标注、模型训练与个体识别.

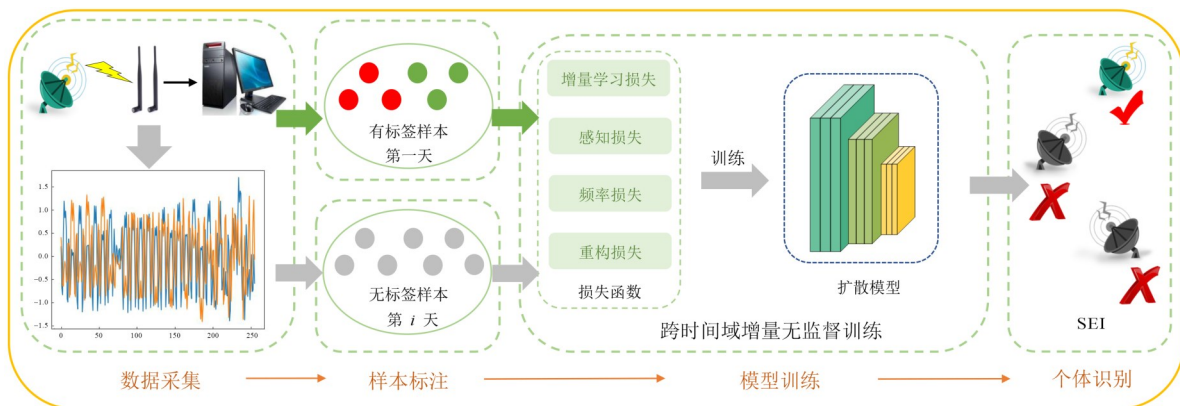


图1 扩散模型驱动的跨时间域SEI方法流

在数据采集阶段,采用实时正交接收机采集多天的通信辐射源个体信号,构建跨时间域数据库.该数据库既包含同一天采集的信号样本,也涵盖跨天条件下的不同信道数据,从而能够较为真实地反映跨时间域识别场景.在样本标注阶段,仅对首日采集的信号进行标注,用作源域训练集;之后各天采集的信号作为目标域无标注样本,用于评估模型在无监督条件下的泛

化与增量学习能力.在模型训练阶段,首先利用源域有标注样本训练扩散模型,以建模和恢复信道特性并提取个体的射频指纹特征;同时在扩散过程中引入跨注意力机制,将设备个体信息嵌入生成过程,以保持特征的区别性.随后利用目标域无标注样本对扩散模型进行增量更新,实现对动态信道条件的自适应及持续学习.在个体识别阶段,将经过扩散模型恢复的信号输

入分类器,完成对通信辐射源个体的识别.与传统增量学习方法不同,本文方法无需目标域标注数据即可在动态环境下持续优化,既保证了长期识别性能,又显著提升了鲁棒性.

### 2.1.2 信号建模与场景描述

考虑在一个开阔无遮挡的区域,有  $N$  个相同类型的发射器和一个接收器.每个发射器以相同的载波频率  $f_s$  发射信号,但发射时刻交错排列,确保每个时间段内仅有一个发射器处于工作状态,以避免信号重叠与干扰.在无线信道和噪声影响下,接收信号  $s(t)$  可建模为

$$s(t) = C_i(r(t)) * h(t) + \eta(t) \quad (1)$$

其中,  $h(t)$  表示信道脉冲响应;  $r(t)$  表示理想基带信号;  $\eta(t)$  为加性白高斯噪声; 符号  $*$  表示卷积操作. 由于每个发射器具有不同的硬件特征,即具有不同的指纹特征,因此本文将  $C_i(\cdot)$  表示第  $i$  个发射器的射频指纹特征. 接收机对频率为  $f_s$  的信号进行采样,得到同相分量  $s_i(n)$  和正交分量  $s_q(n)$ , 作为后续处理的输入.

在辐射源个体识别应用中,识别任务往往具有持续性,需要模型在较长时间跨度内保持有效.然而,受限于实际应用环境和情报支持,通常只有前几天采集的信号能够获得准确标注,并作为训练样本使用;而后续不断采集到的新信号大多缺乏标注.这一特点使得所构建的数据集自然划分为两类:源域标注样本  $\mathcal{S} = \{s_1, s_2, \dots, s_z\}$ , 对应的标签  $\mathcal{L} = \{l_1, l_2, \dots, l_z\}$ . 其主要来自第一天采集,数量充足.目标域无标签样本  $\mathcal{X}^{(0)} = \{x_{i1}, x_{i2}, \dots, x_{ik}\}$ , 来自第  $i$  天的采集,未附带标签.

## 2.2 相关研究

### 2.2.1 领域自适应方法及其在 SEI 中的应用

领域自适应(Domain Adaptation, DA)是迁移学习的重要分支,其目标是在源域训练的模型能够迁移并应用于数据分布存在差异的目标域,尤其在目标域缺乏或完全没有标注样本的情况下具有重要价值.其核心思想是学习一个共享的特征空间,以缩小源域与目标域之间的分布差距,从而提升跨域迁移性能.

根据是否需要访问源域数据,领域自适应方法可分为基于源数据的方法和无源领域自适应(Source-Free Domain Adaptation, SFDA)方法,现有研究大多集中于前者.例如,Chen 等人<sup>[24]</sup>提出了一种原型驱动方法,利用伪标签辅助目标域的自监督训练,在无标签条件下学习判别特征,并在公共数据集上取得了良好效果.Zhang 等人<sup>[25]</sup>结合域对抗神经网络提取域不变特征,从而提高了可变调制信号的识别性能.相比之下,无源领域自适应的探索相对较少,但在图像处理任务中已展现出潜力.Ma 等人<sup>[26]</sup>基于样本特征相似性构建

教师、学生和师生三种关系图,并引入一致性正则化实现有效适应,在多个基准数据集上表现优异.Yan 等人<sup>[27]</sup>则在均值教师框架中结合伪标签学习与软关系一致性,在无需访问源域数据的情况下实现了对目标域的自适应.

值得注意的是,本文采用的 SFDA 方法,即无需访问源域数据.这种方法与传统领域自适应方法不同,后者通常依赖源域数据进行训练和优化,而源域数据的使用会增加存储成本,并且在许多实际应用中不可行.在本文中,由于我们关注的是目标域无标注样本的情况,因此选择了源域无关的 DA 方法,避免了如 ER 等方法带来的存储和计算资源消耗问题.

然而,现有领域自适应方法仍存在一些局限性.首先,很多领域自适应方法缺乏持续学习能力,面对多个不断变化的目标域时,往往难以保持稳定的性能.其次,不同领域之间的差异具有高度多样性,使得通用的领域自适应策略设计变得复杂.这些问题凸显了在 SEI 应用中,不仅需要提升领域自适应的准确性,还必须增强其在动态环境下的稳定性与通用性.此外,虽然现有的 DA 方法可以通过学习共享特征空间来缓解目标域无标注数据的困难,但它并未直接解决标注问题.DA 方法通过迁移学习和自适应能力来减少对标注数据的依赖,但在复杂动态环境下仍需进一步优化以提高适应性.

### 2.2.2 增量学习方法及其在 SEI 中的应用

增量学习,也称为持续学习,旨在使模型能够不断从新样本中学习并更新知识,同时尽可能保留已有知识.这种具备持续学习能力的动态模型在实际应用中至关重要,尤其在 SEI 任务中,由于信道条件、调制参数以及接收机硬件的随机变化,模型需要具备快速适应新环境并保持识别精度的能力.因此,如何在不丧失先前学习能力的情况下,处理不同时间段内采集的目标域信号数据,成为提升 SEI 性能的关键挑战.

当前的增量学习方法通常依赖目标域的标注数据,主要可以分为两大类:类增量学习和任务增量学习.类增量学习的核心问题是如何在新的类别出现时进行有效地识别与学习.例如,杨宁等人<sup>[28]</sup>提出了一种基于元学习的小样本类增量辐射源识别方法,该方法通过伪类增量训练模式替代传统的离线训练,并结合元学习策略优化参数更新机制,从而使得模型能够在极少的新样本条件下快速适应并扩展识别能力.Li 等人<sup>[29]</sup>则引入自监督对比学习,通过增加类间距离并减少类内距离,提高了模型在新类别到来时的泛化能力.

与类增量学习不同,任务增量学习侧重于如何通过约束模型,使其能够在不同任务或数据集之间进行

持续学习,保持跨任务的性能稳定. 本文提出的跨时间域增量学习方法,便属于任务增量学习的范畴. 例如,张立民等人<sup>[30]</sup>通过参数搜索策略确定最佳隐含层数和节点个数,实现了对多批次标记样本的连续在线匹配. Hua 等人<sup>[31]</sup>提出了一种基于知识图驱动的增量宽度学习方法,显著提升了 SEI 算法的识别性能和计算效率.

然而,现有的增量学习方法通常假设目标域存在足够的标注样本,且忽略了由于不同时间段信号特征叠加而可能引发的挑战. 在跨时间域 SEI 任务中,信号随时间的变化、设备状态的波动,以及目标域样本的无标注特性,都使得传统增量学习方法难以直接应用. 因此,如何在目标域没有标注样本的情况下,同时考虑时间段间信号特征的变化,成为了当前增量学习方法 SEI 中应用的关键问题.

### 3 跨时间域 SEI 方法

在跨时间域辐射源个体识别任务中,信道条件会随着时间的推移不断演化,使得设备个体特征与信道特征高度耦合,从而导致识别性能显著下降. 为应对这一问题,本文提出了一种扩散模型驱动的跨时间域 SEI 方法. 该方法首先利用扩散模型对源域(首日)信号进行建模,使模型能够同时捕获源域的个体特征与信道特征;随后,引入跨注意力机制以增强个体特征的鲁棒性,并结合增量学习策略,实现模型在目标域无标注条件下的信道恢复与特征适应.

#### 3.1 框架概述

图 2 展示了本文提出的跨时间域 SEI 方法的整体架构与工作流程,包含四个关键阶段:分类模型预训练、扩散模型预训练、伪标签标注以及无监督增量学习.

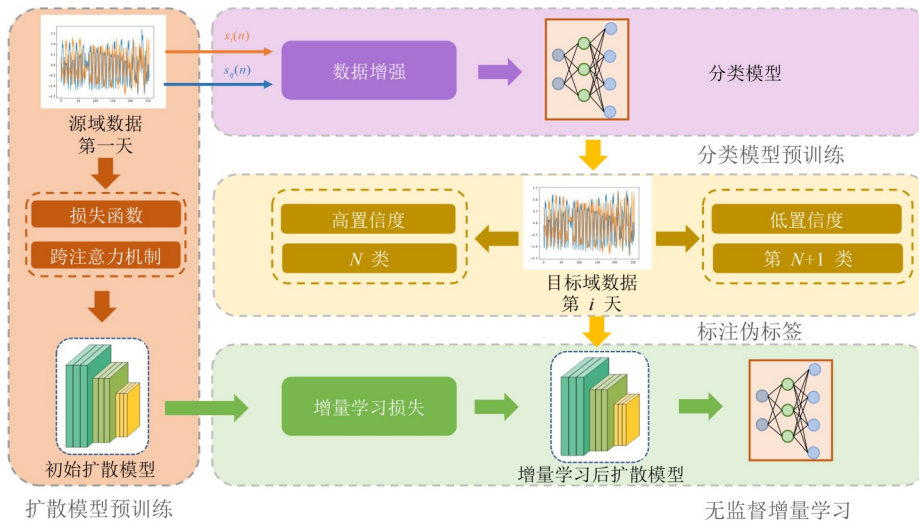


图 2 跨时间域 SEI 方法的整体架构与工作流程

首先,在分类模型预训练阶段,利用首日采集的标注样本训练分类模型,得到具有先验知识的基础识别模型. 接着,在扩散模型预训练阶段,引入跨注意力机制并结合精心设计的损失函数,利用首日训练样本优化扩散模型,使其能够学习特定信道条件下的数据分布,同时有效保留设备的个体特征. 在伪标签标注阶段,考虑到扩散模型本身不具备分类能力,若简单地将后续样本全部视为未知类,会导致不同个体特征发生混淆并造成识别性能下降. 为此,本文提出一种基于置信度的混合伪标签策略:对于高置信度预测的样本,分配相应的伪标签,以充分利用可靠的分类信息;而对于低置信度样本,则统一标记为未知类,以灵活应对特征不确定的数据. 此外,针对目标域样本无标注的特性,在训练阶段将部分已标注训练样本划分为第 7 类(在原有 6 个已知类别之外),以提升扩散模型在重构无标注

样本时的泛化能力,从而增强不同信道条件下的鲁棒性. 最后,在无监督增量学习阶段,利用目标域的无标注样本进行模型更新,并采用弹性权重固化<sup>[13]</sup>策略保护扩散模型的重要权重参数,在学习目标域特征的同时尽可能保留源域的知识,使模型具备持续学习能力和跨时间域适应性.

#### 3.2 分类模型预训练

在分类模型预训练阶段,本文采用 ResNet-18<sup>[32]</sup>作为基架构,以构建稳健的辐射源个体识别模型. 首日采集的标注数据包含六个样本量充足的辐射源个体,用于训练模型以确保充分的特征学习能力. 为了增强模型在信道变化下的鲁棒性,并提高后续伪标签生成的准确性,训练过程中引入了在前期工作中提出的数据增强策略,包括随机裁剪、相位旋转和噪声扰动. 由于这些策略已在文献<sup>[33]</sup>中得到详细介绍,本文不再赘

述. 在经过充足样本的训练后, 该模型在源域数据上的识别准确率可接近 99%, 表明模型具备可靠的特征提取和分类能力. 训练完成后的模型将被保存, 并在后续流程中承担两个关键角色: 一是作为伪标签生成的初始分类器, 二是结合扩散模型的信号恢复结果完成分类识别, 从而为整个跨时间域 SEI 方法提供基础支撑.

### 3.3 扩散模型预训练

扩散模型是一类基于逐步生成思想的深度生成框架, 其核心由正向扩散过程与反向重建过程两部分构成. 在正向扩散阶段, 原始样本  $x_0$  会通过马尔可夫链逐步叠加噪声, 经过  $T$  步迭代后逐渐逼近高斯分布; 而在反向阶段, 训练得到的神经网络则以噪声为起点, 逐层去噪并重构样本, 从而恢复接近原始数据的信号. 这一机制可以类比为通信信号在真实信道中的传输: 正向扩散过程对应信号受到噪声与衰减的干扰, 而反向过程则学习如何逆转这种退化, 实现对信道条件下退化数据的恢复. 值得注意的是, 扩散模型在逐步去噪的过程中不仅能够还原整体波形, 还能捕捉信号中微弱而稳定的设备“指纹”特征, 从而显著提升跨时间域条件下的识别鲁棒性. 凭借这种逐层重建能力, 扩散模型能够有效表征复杂的非线性信道效应及噪声扰动, 为跨时间域 SEI 提供高质量的信号重构与特征支撑.

#### 3.3.1 正向扩散阶段

在扩散模型的前向扩散阶段, 原始数据  $s_0$  会在  $T$  步迭代过程中逐步注入噪声, 使其分布逐渐逼近高斯分布. 设原始数据  $s_0$  服从分  $q(s_0)$ . 为了实现这一逐步扰动过程, 预定义一个随时间步递增的噪声方差序列  $\{\beta_t\}_{t=1}^T$ :

$$0 < \beta_1 < \beta_2 < \dots < \beta_T < 1 \quad (2)$$

在前期迭代中, 由于信号本身质量较高, 只需注入较小幅度的噪声即可对其造成显著扰动. 因此, 我们在初始阶段设置较低的噪声方差. 为便于后续推导与计算, 引入一个缩放系数用于规范化相关表达式:

$$\alpha_t = 1 - \beta_t, \quad \bar{\alpha}_t = \prod_{i=1}^t \alpha_i \quad (3)$$

需要注意的是, 在该扩散过程中, 第  $t$  步的信号状态 (记为  $s_t$ ) 仅依赖于前一时刻状态  $s_{t-1}$ , 因此该过程满足马尔可夫性质, 其条件概率分布可表示为

$$q(s_t | s_{t-1}) = \mathcal{N}(s_t; \sqrt{\alpha_t} s_{t-1}, \beta_t \mathbf{I}) \quad (4)$$

其中,  $\mathbf{I}$  表示单位矩阵. 依据马尔可夫链的条件独立性, 可以将前向扩散过程的联合概率分布表示为

$$q(s_{1:T} | s_0) = \prod_{t=1}^T q(s_t | s_{t-1}) \quad (5)$$

结合独立高斯随机变量的统计性质与重参数化方法, 可以将多步扩散的累积效果推导为一个闭式表达

式, 其形式可写作:

$$q(s_t | s_0) = \mathcal{N}(s_t; \sqrt{\bar{\alpha}_t} s_0, (1 - \bar{\alpha}_t) \mathbf{I}) \quad (6)$$

尽管前向过程在形式上被划分为  $T$  个连续的迭代步, 但由于其满足马尔可夫性质, 结合重参数化技巧, 可以跳过逐步计算, 直接从初始状态生成目标时刻  $t$  的数据, 实现高效的采样与模拟.

#### 3.3.2 反向重建阶段

在反向扩散阶段, 模型的目标是逐步消除前向过程中注入的噪声, 并从近似高斯分布中逐步重建原始信号. 与前向过程类似, 反向过程同样被建模为一个马尔可夫链, 其条件概率分布  $p_\theta(s_{t-1} | s_t)$  由可学习参数的神经网络进行建模.

本文受 DDPM 扩散模型<sup>[19]</sup>的启发, 选用 U-Net 架构作为去噪网络. 给定带噪样本  $s_t$  及对应时间步  $t$ , 网络直接预测噪声项  $\epsilon_\theta(s_t, t)$ . 基于该预测结果, 可以推导出  $s_t$  的后验均值  $\mu_\theta$  和方差  $\sum_\theta$ :

$$\mu_\theta = \frac{1}{\sqrt{\alpha_t}} \left( s_t - \frac{\beta_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_\theta(s_t, t) \right) \quad (7)$$

$$\sum_\theta(s_t, t) = \tilde{\beta}_t \mathbf{I} \quad (8)$$

其中,  $\tilde{\beta}_t$  是“修正后的方差”, 由前向过程的累积参数决定:

$$\tilde{\beta}_t = \frac{1 - \bar{\alpha}_{t-1}}{1 - \bar{\alpha}_t} \beta_t \quad (9)$$

在每一次反向迭代中, 采样过程均按照下述方式执行:

$$s_{t-1} = \begin{cases} \mu_\theta + \sqrt{\tilde{\beta}_t} \epsilon', & t > 0 \\ \mu_\theta, & t = 0 \end{cases} \quad (10)$$

其中,  $\epsilon'$  表示标准高斯噪声, 用于保证生成样本的多样性. 同时, 输出会被限制在预设的数值范围内, 以避免数值不稳定或溢出. 通过这样的训练机制, U-Net 网络能够有效学习噪声分布, 从而准确估计后验分布的参数, 使反向扩散过程能够逐步完成去噪并重构接近真实信号的样本.

#### 3.3.3 跨注意力机制

跨注意力机制可以视作自注意力机制的一种扩展, 其核心思想是在注意力计算中引入额外的输入序列, 从而实现多源信息的融合<sup>[34]</sup>. 在本任务中, 由于不同发射器的特征差异往往较为细微, 而扩散模型本身虽具备较强的生成能力, 却缺乏有效的判别能力, 如果不引入跨注意力机制, 模型容易将来自不同发射器的样本混淆, 甚至对同一发射器的不同样本产生错误分类. 为解决这一问题, 本文在扩散模型中引入跨注意力结构, 将标签信息作为辅助上下文嵌入, 与信号特征联

合建模,从而增强模型对细微个体差异的捕捉能力,提升判别性能与鲁棒性.

设训练样本序列为  $\mathcal{S}=\{s_1, s_2, \dots, s_z\}$ , 对应的标签  $\mathcal{L}=\{l_1, l_2, \dots, l_z\}$ , 其中, 标签嵌入在跨注意力模块中作为上下文表示参与运算. 扩散模型的瓶颈特征可表示为  $b \in \mathbb{R}^{B \times G \times D}$ , 其中  $B$  为批大小,  $G$  为通道数,  $D$  为序列长度维度. 时间步嵌入  $e_{\text{time}} \in \mathbb{R}^{B \times G \times 1}$  被加入瓶颈特征以建模时序信息:

$$b' = b + e_{\text{time}} \quad (11)$$

为进一步增强模型在标签缺失或不确定情况下的鲁棒性, 训练阶段引入了概率标签剔除策略, 即以概率  $pr$  将批次中的部分标签替换为一个额外的“未知”类别, 从而将原有标签空间由  $N$  扩展至  $N+1$ . 设修改后的标签  $l'$  为

$$l' = \begin{cases} l, & \text{概率为 } 1 - pr \\ \text{未知类}, & \text{概率为 } pr \end{cases} \quad (12)$$

在跨注意力模块中, 处理后的瓶颈特征  $b'$ , 被视作查询向量  $\mathbf{j}$ , 而根据  $l'$  得到的标签嵌入则分别作为关键向量  $\mathbf{m}$  与值向量  $\mathbf{v}$  输入注意力计算过程:

$$\mathbf{j} = W_q b', \quad \mathbf{m} = W_k e_{l'}, \quad \mathbf{v} = W_v e_{l'} \quad (13)$$

其中,  $W_q, W_k$  和  $W_v$  为可学习的线性投影参数;  $e_{l'}$  表示可能经过标签剔除策略调整后的标签嵌入向量.

缩放点积注意力的权重计算为

$$\text{Attn}(\mathbf{j}, \mathbf{m}, \mathbf{v}) = \text{Softmax} \left( \frac{\mathbf{j} \mathbf{m}^T}{\sqrt{d_k}} \right) \mathbf{v} \quad (14)$$

其中,  $d_k$  为关键向量的维度.

得到的注意力输出  $b_{\text{out}} = \text{Attn} \mathbf{v}$  经投影回瓶颈特征的维度后, 与原始瓶颈特征  $b'$  进行融合, 得到一个融合了标签上下文的增强表示. 通过这种机制, 网络能够有效整合标签信息来提取个体级细粒度特征, 同时对缺失或不确定标签保持鲁棒性, 最终提升整体判别性能.

### 3.3.4 损失函数

在预训练阶段, 为了全面衡量模型预测噪声与真实噪声之间的差异, 本文构建了一个由多种误差项加权组合的复合损失函数. 设模型预测的噪声为  $\hat{\varepsilon}$ , 真实噪声为  $\varepsilon$ , 批量大小为  $B$ , 总体损失可表示为

$$\mathcal{L}_{\text{pretrain}} = \lambda_1 \mathcal{L}_{L1} + \lambda_2 \mathcal{L}_{\text{MSE}} + \lambda_3 \mathcal{L}_{\text{freq}} \quad (15)$$

其中,  $\lambda_1, \lambda_2$  和  $\lambda_3$  分别为各损失分量的权重, 取值通过经验设定;  $\mathcal{L}_{L1}$  为平均绝对误差;  $\mathcal{L}_{\text{MSE}}$  为均方误差;  $\mathcal{L}_{\text{freq}}$  为频域误差.

平均绝对误差用于直接评估时域预测噪声与真实噪声在元素级的差异, 其定义为

$$\mathcal{L}_{L1} = \frac{1}{B} \sum_{i=1}^B \|\hat{\varepsilon}_i - \varepsilon_i\|_1 \quad (16)$$

均方误差衡量预测与真实噪声信号的平方差平均

值, 更关注较大偏差的惩罚, 定义为

$$\mathcal{L}_{\text{MSE}} = \frac{1}{B} \sum_{i=1}^B \|\hat{\varepsilon}_i - \varepsilon_i\|_2^2 \quad (17)$$

单纯的时域误差可能无法充分刻画信号的频率特征, 因此本文在损失中引入频域成分. 首先, 将预测噪声和真实噪声的同相与正交分量视为复数信号  $\hat{s}(t)$  和  $s(t)$ , 然后进行快速傅里叶变换, 得到频谱  $F(\hat{s}(t))$  和  $F(s(t))$ . 在对频谱幅值做对数缩放后, 定义频域损失为

$$\mathcal{L}_{\text{freq}} = \frac{1}{m} \sum_{k=1}^m \left| \log |F(\hat{s}(t))_k| - \log |F(s(t))_k| \right| \quad (18)$$

其中,  $m$  表示频谱的长度.

综上所述, 本文在扩散模型的预训练阶段引入了由重构损失、感知损失以及频域损失共同构成的复合损失函数. 其中, 感知损失在时域约束下有助于保留细节并抑制异常值的影响, 重构损失对整体重构误差提供全局性约束, 而频域损失则有效补充了对谱结构的刻画能力. 该组合方式在时域与频域两方面形成互补, 有助于生成信号在波形和频谱形态上同时逼近真实分布, 从而为后续增量学习阶段的特征迁移与生成质量提供坚实基础.

### 3.4 伪标签标注

在本文方法中, 伪标签标注阶段是连接无标签样本与扩散模型识别能力的重要环节. 由于扩散模型本质属于生成模型, 缺乏显式的判别能力, 若直接将无标签样本送入生成流程, 其输出在特征层面可能会混入其他个体的特征模式, 导致不同通信辐射源个体间的特征融合与混淆, 从而降低个体识别的准确性. 为克服这一问题, 本文引入伪标签标注机制, 在无标签数据与扩散模型之间建立额外的类别引导.

具体而言, 首先利用已经训练完成的分类器对未标注样本进行预测, 并获得各类别的后验概率分布. 令

$$\hat{y} = \arg \max_{c \in \{1, 2, \dots, N\}} p_{\theta}(c|x) \quad (19)$$

其中,  $p_{\theta}(c|x)$  表示分类器在输入样本  $x$  预测其属于类别  $c$  的概率. 为保证伪标签的可靠性, 引入置信度筛选策略:

$$\hat{y} = \begin{cases} \arg \max_c p_{\theta}(c|x), & \max_c p_{\theta}(c|x) \geq \tau \\ N+1, & \text{其他} \end{cases} \quad (20)$$

其中,  $\tau$  为置信度阈值. 当最高类别概率不低于  $\tau$  时, 将该类别作为样本的伪标签; 反之, 则将其标记为“未知”类别  $N+1$ , 以避免错误标签干扰后续建模.

### 3.5 无监督增量学习

在扩散模型预训练与伪标签标注的基础上, 本文进一步引入无监督增量学习机制, 以适应目标域中不断到来的新数据并缓解模型遗忘问题. 由于目标域样本在实际应用中通常缺乏人工标注, 若直接用于训练

可能导致模型对旧类别知识的遗忘,同时对新知识的适应能力不足.为此,本文将目标域的无标签样本视为未知类(即类别  $N+1$ ),并在跨注意力机制中输入,以此显式区分来自源域的已知类别与目标域的未标注样本.

在优化目标上,本文在预训练阶段的复合损失基础上,引入了 EWC<sup>[13]</sup> 正则化项,从而抑制参数在增量阶段的过度偏移.具体而言,EWC 通过引入 Fisher 信息矩阵来衡量模型参数对先前任务的重要性,并在训练过程中对重要参数的更新施加额外惩罚.其损失函数可表述为

$$\mathcal{L}_{\text{EWC}} = \frac{\delta}{2} \sum_i F_i (\theta_i - \theta_i^*)^2 \quad (21)$$

其中,  $\theta_i$  表示当前模型参数;  $\theta_i^*$  为先前任务的最优参数;  $F_i$  为基于 Fisher 信息矩阵估计的第  $i$  个参数的重要性度量;  $\delta$  为调节参数更新幅度的权重系数.通过该正则化约束,模型能够在学习新任务时保留对旧任务的重要参数,从而有效缓解灾难性遗忘问题.

基于此,无监督增量学习阶段的总损失函数可写为

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{pretrain}} + \lambda_4 \mathcal{L}_{\text{EWC}} \quad (22)$$

其中,  $\lambda_4$  为增量学习损失的权重.

综上,本文在无监督场景下通过伪标签标注机制获取辅助监督信息,并在增量学习阶段结合 EWC 正则约束,实现了对新数据的适应与旧知识的保持.该设计使模型能够在长期任务序列中维持稳定的识别性能,同时提升跨域泛化能力,为实际复杂环境下的持续学习提供了可行路径.

## 4 实验与分析

### 4.1 数据集介绍与参数设置

为全面验证本文所提出的跨时间域 SEI 方法的有效性,实验采用文献[23]中公开的 WiSig 数据集的 ManySig 子集.该子集由 6 个不同的 WiFi 发射设备在 12 个接收机端采集所得,每个发射设备提供 1 000 个样本,每个样本包含 256 个复值 I/Q 采样点.数据采集覆盖 4 个不同时段:2021 年 3 月 1 日(0301)、3 月 8 日(0308)、3 月 15 日(0315)与 3 月 23 日(0323),形成了显著的跨时间/跨信道分布差异,适用于评估跨域条件下的设备指纹识别性能.

在数据预处理阶段,所有信号样本均以原始 I/Q 形式输入,不进行额外的手工特征工程.实验遵循源域/目标域划分策略:将首日(0301)数据作为源域(有标签),其余三日作为目标域(无标签),以模拟实际应用中跨信道、跨时间的无监督增量学习场景.

实验环境方面,硬件平台为 Intel Core i9-13900K 与

NVIDIA GeForce RTX 3070 Ti;软件环境为 Python 3.9.13、PyTorch 1.13.1 与 CUDA 11.7.训练相关的关键超参数(包括扩散过程噪声步数  $T$ ,复合损失权重  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$ 、 $\lambda_4$  等)详见表 1.

表 1 参数设置

参数名称	定义
个体数	6
采样点数	256
样本数	1 000
优化器	Adam(学习率为 0.000 1)
$\lambda_1$	1.0
$\lambda_2$	1.1
$\lambda_3$	0.01
$\lambda_4$	1.0
$T$	1 000
$B$	256
$\tau$	0.95
$\delta$	1.0
pr	15%

### 4.2 算法性能分析


#### 4.2.1 生成信号效果分析

本节选取 2021 年 3 月 1 日数据(记作 0301)作为源域,2021 年 3 月 8 日数据(记作 0308)作为目标域,进行信号生成与对比分析.结果如图 3 所示,其中图 3(a)为同相分量(I路)信号,图 3(b)为正交分量(Q路)信号,图 3(c)为其对应的频谱.从图 3 可以观察到,所提出的扩散模型能够在一定程度上减弱跨时间信道变化带来的影响,并较好地保留发射端的个体指纹特征.然而,尽管生成信号的整体分布与源域信号更为接近,扩散过程不可避免地引入了一定的噪声,特别是在频谱层面.频谱分析结果表明,生成信号在与源域信号的频谱特性上存在一定的差异,尽管这种差异在一些场景中可能并不显著,但噪声的引入仍然对信号的质量和后续识别过程带来了挑战.


为缓解这一问题,本文在训练过程中引入了频域损失项,旨在约束生成信号的频谱特性,使其更加接近源域信号的频谱特征.通过这一策略,我们能够在一定程度上减小信号生成过程中的噪声影响,改善目标域信号的质量.尽管如此,噪声问题仍然是生成信号分析中的一个不可忽视的挑战,未来研究可进一步探索在更复杂环境下的噪声抑制方法,以提高生成信号的可靠性和识别性能.

此外,还可以注意到,源域与目标域信号在波形和频谱层面上的差异并不显著.这一现象可能与数据采集环境有关.由于该数据集主要在受控的实验室环境下采集,信道变化较小,因此源域和目标域信号之间的


分布差异较为有限. 未来研究中,将考虑在更为复杂、不可控的环境下进行数据采集,进一步验证所提方法在实际应用中的鲁棒性.



(a) 同向信号恢复可视化



(b) 正交信号恢复可视化



(c) 频谱可视化

图3 跨信道信号生成效果

#### 4.2.2 与源域单独训练模型的性能比较

为验证本文方法在跨时间域SEI场景下的有效性,本文引入仅在源域数据上训练的基线模型(Source Only)作为参照. 实验结果如表2所示. 在源域数据集上,本文方法与Source Only模型分类准确率相当,说明基于扩散模型的增量学习在保持旧域知识方面表现

良好,并未因目标域无标签样本的引入而导致灾难性遗忘. 这表明扩散模型能够有效地编码并保留源域特征,使增量学习阶段在引入新数据时依然稳定. 在目标域数据集上,本文方法的分类准确率相比Source Only模型提升显著,增幅通常超过10个百分点,在部分日期甚至达到20个百分点. 这一结果证明了所提方法能够更好地适应跨时间信道差异,显著提升跨域识别性能. 进一步观察发现,在0301-0323的跨时间实验中,本文方法取得最高准确率,而在0301-0315的情况下准确率最低. 这表明0323与0301的信道条件相对接近,使得扩散模型的还原更为有效;相对地,0315与0301的信道差异更大,导致恢复性能有所下降. 值得注意的是,这一结果与通常认为“时间跨度越大,信道差异应更显著”的经验假设存在一定偏差,可能的原因在于本数据集采集于受控实验室环境,使得不同日期期间的信道漂移幅度整体有限.

表2 跨时间域SEI方法与仅使用源域训练模型在不同目标域下的性能对比 单位:%

方法	域名	0301-0308	0301-0315	0301-0323
Source Only	源域	99.72	99.72	99.72
	目标域	78.33	73.53	83.33
跨时间域SEI方法	源域	96.16	96.08	97.88
	目标域	<b>91.46</b>	<b>90.87</b>	<b>97.76</b>

注:粗体表示最优结果.

#### 4.2.3 与领域自适应方法的性能比较

为了评估本文提出的方法在跨时间域方面的性能,本节将其与3种代表性先进方法进行对比:SHOT-SEI<sup>[10]</sup>、Tent<sup>[11]</sup>和数据增强<sup>[33]</sup>. 其中,SHOT-SEI与Tent均属于无需访问源域数据的领域自适应方法,但它们依赖于目标域样本进行自适应训练. 为了确保公平比较,每个个体在目标域中的样本数量均限制为100. 数据增强方法采用了文献[33]中的3种增强策略,即相位旋转、随机裁剪与抖动,以提升样本多样性和模型泛化能力.

实验结果如表3所示,以2021年3月1日(0301)的数据集作为源域,3月8日(0308)、3月15日(0315)和3月23日(0323)的数据集作为目标域时,所提方法在识别准确率上均显著优于上述领域自适应与数据增强方法. 尤其是在0323作为目标域时,本文方法的识别准确率高达97.76%,已接近在源域测试时的性能水平. 这一结果表明,所提跨时间域SEI方法能够有效缓解信道变化的影响,并在跨信道条件下保持稳定的识别性能.

需要注意的是,当0315作为目标域时,所提方法的识别准确率下降至90.87%. 这一性能下降可能与0315和0301之间存在较大的信道差异有关,该差异可能导

表3 跨时间域SEI方法与典型领域自适应方法在不同目标域下的性能对比 单位:%

方法	0301-0308	0301-0315	0301-0323
SHOT-SEI	85.88	83.33	95.92
Tent	83.33	80.23	85.48
数据增强	82.83	78.00	86.06
跨时间域SEI方法	<b>91.46</b>	<b>90.87</b>	<b>97.76</b>

注:粗体表示最优结果。

致伪标记生成阶段出现一定比例的错误标签,进而影响最终分类结果.这一现象也提示扩散模型在应对严重信道变化时,信号还原仍存在一定的挑战性.

训练样本规模是影响SEI方法性能及其实际应用的重要因素.为进一步分析在样本数量有限的情况下各方法的表现,本文固定源域为2021年3月1日(0301)、目标域为2021年3月15日(0315),并将目标域每个个体的训练样本数量分别设置为25、50、75和100.表4给出了本文方法与3种领域自适应方法在不同样本规模下的识别准确率对比结果.实验结果表明,随着样本数量的增加,所有方法在目标域的识别准确率均有所提升,验证了训练样本规模对模型性能的积极作用.值得注意的是,本文方法在训练样本减少时表现出较强的鲁棒性,当样本数量从100个减少至25个时,准确率仅由90.87%下降至84.76%(降幅约6个百分点);相比之下,SHOT-SEI等其他方法的准确率下降幅度接近10个百分点.这种较高的鲁棒性可以归因于扩散模型的特性:尽管较大的样本规模能够进一步提升生成质量,但与纯分类模型相比,扩散模型在训练中对样本数量的依赖度更低.通过在生成过程中逐步添加噪声并执行去噪重建,扩散模型能够有效学习目标域信道的统计分布,从而在样本稀缺的情况下依然保持较为稳定的识别性能.

表4 跨时间域SEI方法与典型领域自适应方法在不同样本下的性能对比 单位:%

方法	25	50	75	100
SHOT-SEI	73.43	80.06	82.64	83.33
Tent	71.86	75.43	77.37	80.23
数据增强	69.53	72.98	75.35	78.00
跨时间域SEI方法	<b>84.76</b>	<b>86.46</b>	<b>88.41</b>	<b>90.87</b>

注:粗体表示最优结果。

#### 4.2.4 与增量学习方法的遗忘性能比较

为进一步验证本文方法在防止灾难性遗忘方面的有效性,本节将其与3种具有代表性的增量学习方法进行对比:LWF<sup>[12]</sup>、EWC<sup>[13]</sup>和ER<sup>[14]</sup>.在实验中,我们采用增量样本学习的方式,对各方法进行持续训练,并在训练完成后计算其在源域数据上的性能下降幅度,从而得到遗忘率(Forgetting Rate)曲线.实验结果如图4所

示.从图4可以观察到,随着训练样本数量的增加,各方法的遗忘率均呈现一定程度的上升趋势.然而,本文方法的遗忘率始终保持在较低水平,即便在样本数量从25增加至100的过程中,遗忘率增幅仍控制在5个百分点以内.相比之下,LWF、EWC以及ER等主流方法在相同条件下均出现更为显著的遗忘现象.

这一结果表明,所提方法在增量学习场景下展现出更强的抗遗忘能力.其原因在于扩散模型在信号建模过程中通过逐步加噪与去噪过程,有效保留了源域信道的潜在分布信息,从而在引入新样本时减少了对既有知识的覆盖与遗失.这一特性使得本文方法不仅能够跨时间域任务中保持较高的识别准确率,同时也能在持续学习环境下维持对源域知识的记忆,显著缓解灾难性遗忘问题.




图4 增量学习方法的遗忘率曲线

#### 4.2.5 计算复杂性分析

尽管本文方法在目标域识别准确率方面显著优于典型领域自适应方法,但其训练过程依赖于扩散模型,因此在计算复杂性上具有更高的开销.具体来说,扩散模型在训练过程中对计算资源的需求较大,特别是在U-Net结构的引入上,使得相较于传统的增量学习方法,计算成本有所增加.表5中列出了不同SEI算法的计算成本,表明本文方法在计算量上明显高于领域自适应方法,但略低于以ResNet-18为核心的传统增量学习方法.

在每秒浮点运算次数(Floating Point Operations Per Second, FLOPS)方面,本文方法的计算量虽然较大,但仍具有一定优势,尤其是在参数量方面.具体而言,尽管扩散模型需要处理较为复杂的训练过程,其计算负担主要集中在U-Net生成网络上,相较于传统的分类模型,其复杂度较低.因此,尽管本文方法在计算复杂性上存在一定的提升,但这一部分的开销在跨时间域SEI任务中通过更高的识别准确率和更强的抗灾难遗忘能

表 5 不同方法的计算复杂性对比

方法	参数量/M	FLOPS/MMAC
SHOT-SEI	3.85	43.98
Tent	3.85	43.98
数据增强	3.85	824.54
EWC	3.85	824.54
LWF	3.85+3.85	1 649.07
ER	3.85	824.54
跨时间域 SEI 方法	<b>3.85+1.97</b>	<b>106.75</b>

注:粗体表示最优结果.

力得以弥补.

然而,值得注意的是,随着计算需求的增加,实际应用中的计算资源限制可能会对算法的部署产生影响. 因此,在未来的研究中,进一步优化扩散模型的计算效率,降低其对计算资源的依赖,将是一个重要的改进方向.


#### 4.2.6 基于混淆矩阵与 t-SNE 的特征分布可视化

为了更直观地展示所提方法在跨时间域任务中的特征分布情况,本文采用 t-分布随机邻域嵌入(t-distributed Stochastic Neighbor Embedding, t-SNE)<sup>[35]</sup>对提取的高维语义特征进行降维处理,并在二维空间中进行可视化. t-SNE 能够在保持数据局部邻域结构的同时,突出不同类别样本之间的相似性与差异性,因此常用于分析模型学习到的特征表达能力. 在绘图中,源域样本以圆圈表示,目标域样本以星形表示,以便于对比两域特征的分布关系. 图 5 给出了 3 组跨时间域任务的可视化结果,分别对应 0301-0308、0301-0315 和 0301-0323. 从结果可以看出,随着扩散模型的特征变换作用,源域与目标域样本的分布逐渐贴近. 在 0301-0323 任务中,两域样本几乎完全重叠,类别边界清晰,错误分类点极少,这与前文识别准确率的结果相一致. 而在 0301-0315 任务中,由于信道条件变化较大,同一类样本的特征位置出现了一定偏移,但类内聚集性依然保持较高水平,类别间的分离度同样较好. 这说明本文方法即使在信道变化幅度较大的情况下,依然能够有效保持判别鲁棒性.


综合来看,t-SNE 可视化进一步证明了本文方法在缓解源域与目标域特征分布差异方面的有效性,同时也从特征空间的角度印证了其在跨时间域任务中所具备的鲁棒性与泛化能力.

#### 4.2.7 关键模块消融实验


为进一步验证本文所提跨时间域 SEI 方法中各关键模块的有效性,本节开展了消融实验. 具体地,分别去除无监督增量学习部分与扩散模型训练部分,形成两种退化模型,并与完整方法进行对比. 实验设置与前文保持一致,实验结果如表 6 所示. 由结果可以观察



(a) 0301-0308 特征可视化



(b) 0301-0315 特征可视化



(c) 0301-0323 特征可视化

图 5 t-SNE 特征可视化

到,当移除扩散模型,仅保留增量学习(即退化为 EWC 方法)时,源域识别准确率仅为 72.67%,显著低于完整方法的 96.16%. 这表明扩散模型在防止灾难性遗忘方面发挥了核心作用,有效保持了模型对源域知识的记忆. 另一方面,当移除增量学习阶段,仅使用扩散模型时,目标域识别准确率由 84.17% 提升至 90.87%. 可见,增量学习在提升模型的域迁移能力方面至关重要,使其能够更好地适应目标域分布的变化. 值得注意的是,

扩散模型的引入在提升源域准确率的同时,导致目标域识别率出现小幅下降.然而,考虑到源域性能的显著提升以及整体跨时间域识别精度的改善,这一损失在实际应用中是可以接受的.

表6 跨时间域SEI方法的消融性实验 单位:%

方法	域名	0301-0308	0301-0315	0301-0323
去除增量学习	源域	99.76	99.76	99.76
	目标域	87.39	84.17	96.94
去除扩散模型	源域	72.67	64.44	84.33
	目标域	92.33	91.78	96.50
跨时间域SEI方法	源域	96.16	96.08	97.88
	目标域	<b>91.46</b>	<b>90.87</b>	<b>97.76</b>

注:粗体表示最优结果.

综上所述,扩散模型与增量学习模块在跨时间域SEI框架中各自发挥着不可替代的作用,前者显著缓解了灾难性遗忘,后者则增强了对目标域的适应性,两者协同作用才能保证方法的整体性能.

通过在实测跨时间域任务上的多组对比实验,本文方法在目标域识别准确率、抗灾难性遗忘能力以及跨域特征对齐等方面均表现出优异性能.算法复杂性分析表明,尽管引入扩散模型会增加一定的计算开销,但其在显著提升源域识别精度的同时,保持了较高的目标域性能.t-SNE特征分布可视化与混淆矩阵分析进一步验证了本文方法在缓解信道变化影响、稳定类间边界方面的有效性.消融实验结果表明,扩散模型与增量学习模块在整体框架中缺一不可,二者协同作用实现了对源域和目标域的综合性能优化.以上结果共同证明,本文提出的跨时间域SEI方法在信道条件变化甚至样本有限的实际应用场景中,具有较高的可靠性与推广价值.

## 5 结束语

本文针对信道变化对辐射源个体识别性能造成的影响,提出了一种基于扩散模型的跨信道识别框架.该方法利用扩散模型将目标域信号重构为源域信号,有效捕捉并保留了设备指纹特征;同时结合无监督增量学习,对目标域无标签样本进行持续特征学习,从而显著增强了模型在跨信道场景下的鲁棒性.所提出的跨时间域SEI方法将生成式还原与判别式分类相结合,充分利用了目标域未标记数据的特性,具备较强的信道适应能力.在WiSig跨信道数据集上的实验结果表明,与现有领域自适应方法和增量学习方法相比,本文方法在识别准确率上取得了显著提升,尤其在目标域样本有限的条件下仍表现出良好的稳定性与泛化能力.具体而言,当目标域信道条件与源域相对接近时,识别准确率几乎与源域持平,体现了方法优异的信号还原

效果和域间特征对齐能力.未来的研究将着重提升模型生成样本的伪标签精度,并探索在更加复杂、多变的信道环境中的应用潜力,以应对实际跨信道识别任务中更具挑战性的情况.

## 参考文献

- [1] 刘钊, 马爽, 张梦杰, 等. 多径条件下的雷达辐射源个体识别方法[J]. 电子学报, 2023, 51(6): 1654-1665.  
LIU Z, MA S, ZHANG M J, et al. Radar specific emitter identification method under multipath conditions[J]. Acta Electronica Sinica, 2023, 51(6): 1654-1665. (in Chinese)
- [2] 赵雅琴, 谢丹, 吴龙文, 等. 数字预失真下的辐射源个体识别技术[J]. 电子学报, 2023, 51(11): 3331-3342.  
ZHAO Y Q, XIE D, WU L W, et al. Specific emitter identification under digital pre-distortion[J]. Acta Electronica Sinica, 2023, 51(11): 3331-3342. (in Chinese)
- [3] 袁晔, 汤春阳, 张博轩, 等. 融合时频特征的通信辐射源个体识别方法[J]. 电子测量技术, 2025, 48(1): 129-136.  
YUAN Y, TANG C Y, ZHANG B X, et al. Individual identification method for communication radiation sources by integrating time-frequency characteristics[J]. Electronic Measurement Technology, 2025, 48(1): 129-136. (in Chinese)
- [4] 李奇真, 刘佳旭, 梁先明, 等. 基于深度学习的跨域辐射源个体识别综述[J]. 电讯技术, 2024, 64(7): 1163-1174.  
LI Q Z, LIU J X, LIANG X M, et al. Cross-domain specific emitter identification based on deep learning: A comprehensive survey[J]. Telecommunication Engineering, 2024, 64(7): 1163-1174. (in Chinese)
- [5] 孙丽婷, 柳征, 黄知涛. 接收域分离的跨接收系统通用性辐射源指纹识别[J]. 电子与信息学报, 2024, 46(10): 3966-3978.  
SUN L T, LIU Z, HUANG Z T. Universal radio frequency fingerprinting across receiving systems using receiving domain separation[J]. Journal of Electronics & Information Technology, 2024, 46(10): 3966-3978. (in Chinese)
- [6] 徐宇恒, 程嗣怡, 董晓璇, 等. 基于DBN特征提取的雷达辐射源个体识别[J]. 空军工程大学学报(自然科学版), 2019, 20(6): 91-96, 108.  
XU Y H, GHENG S Y, DONG X X, et al. Radar specific emitter identification based on DBN feature extraction[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(6): 91-96, 108. (in Chinese)
- [7] 王美玉. 数据受限下基于迁移学习的特定辐射源精准识别方法研究[D]. 哈尔滨: 哈尔滨工程大学, 2023.  
WANG M Y. Research on Accurate Identification Method

- of Specific Emitter Based on Transfer Learning under Data Constraints[D]. Harbin: Harbin Engineering University, 2023. (in Chinese)
- [8] 刘振, 陈阿磊, 李世飞, 等. 基于迁移学习的辐射源个体识别分类方法[J]. 舰船电子对抗, 2023, 46(2): 53-60, 78.  
LIU Z, CHEN A L, LI S F, et al. Specific emitter identification and classification method based on transfer learning[J]. Shipboard Electronic Countermeasure, 2023, 46(2): 53-60, 78. (in Chinese)
- [9] XIAO Z L, XIE Y H, LI Q, et al. Cross-domain specific emitter identification based on domain-specific classifier[J]. IEEE Internet of Things Journal, 2025, 12(14): 27660-27670.
- [10] LIANG J, HU D, FENG J. Do we really need to access the source data source hypothesis transfer for unsupervised domain adaptation[C]//International Conference on Machine Learning. Cambridge: PMLR, 2020: 6028-6039.
- [11] VARGAS HAKIM G A, OSOWIECHI D, NOORI M, et al. CLIPArTT: Adaptation of CLIP to new domains at test time[C]//2025 IEEE/CVF Winter Conference on Applications of Computer Vision. Piscataway: IEEE, 2025: 7092-7101.
- [12] 刘展阳, 刘进锋. 基于知识蒸馏的不存储旧数据的类增量学习[J]. 计算机应用, 2024, 44(S2): 12-17.  
LIU Z Y, LIU J F. Data-free class incremental learning based on knowledge distillation[J]. Journal of Computer Applications, 2024, 44(S2): 12-17. (in Chinese)
- [13] WANG S Y, LUO X Q. Incremental learning method for lung nodule detection based on EWC and feature distillation[C]//International Conference on Biomedical and Intelligent Systems (IC-BIS 2022). Chengdu: SPIE, 2022: 868-874.
- [14] DENG Z W, LI C, SONG R C, et al. Centroid-guided domain incremental learning for EEG-based seizure prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2500613.
- [15] 段可欣, 闫文君, 刘凯, 等. 基于动态权重模型的数据不平衡 SEI 方法[J]. 太赫兹科学与电子信息学报, 2024, 22(2): 142-151, 159.  
DUAN K X, YAN W J, LIU K, et al. Data imbalance SEI method based on dynamic weight model[J]. Journal of Terahertz Science and Electronic Information Technology, 2024, 22(2): 142-151, 159. (in Chinese)
- [16] GUO H, GU Y N, ZHAO J Y, et al. Multiscale attention denoising diffusion probability model for multilingual handwriting character recognition[J]. The Visual Computer, 2025, 41(11): 8467-8485.
- [17] ZHANG C, YANG W X, LI X, et al. MMGINpainting: Multi-modality guided image inpainting based on diffusion models[J]. IEEE Transactions on Multimedia, 2024, 26: 8811-8823.
- [18] YING Z L, KE W Y, ZHAI Y K, et al. DiffuSAR: Frequency domain-aware diffusion model for SAR image generation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2025, 18: 11851-11866.
- [19] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. New York: ACM, 2020: 6840-6851.
- [20] WANG W Y, DOU Z, FU J Z, et al. A diffusion model-based open set identification method for specific emitters[C]//2023 IEEE/CIC International Conference on Communications in China. Piscataway: IEEE, 2023: 1-5.
- [21] ZHA H R, WANG W Y, YU S, et al. SEI-DM: Crafting revolutionary RF signals in low-resource settings via diffusion model[C]//2023 IEEE 23rd International Conference on Communication Technology. Piscataway: IEEE, 2024: 890-895.
- [22] ROMBACH R, BLATTMANN A, LORENZ D, et al. High-resolution image synthesis with latent diffusion models[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2022: 10674-10685.
- [23] 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.
- [24] CHEN J W, YU L, CHEN Y F, et al. Prototype-driven unsupervised domain adaptation for specific emitter identification[J]. IEEE Internet of Things Journal, 2025, 12(1): 637-649.
- [25] ZHANG X L, LI T Y, GONG P, et al. Variable-modulation specific emitter identification with domain adaptation[J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 380-395.
- [26] MA Y, CHAI L, TU S, et al. Exploring relational knowledge for source-free domain adaptation[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2025, 35(2): 1825-1839.
- [27] YAN L, ZHENG W B, LI K L. Source-free domain adaptive person search[J]. Pattern Recognition, 2025, 161: 111317.

- [28] 杨宁, 张邦宁, 郭道省. 基于元学习的小样本类增量辐射源个体识别方法[J]. 陆军工程大学学报, 2025, 4(4): 46-52.  
YANG N, ZHANG B N, GUO D X. Few-shot class-incremental specific emitter identification method based on meta-learning[J]. Journal of Army Engineering University of PLA, 2025, 4(4): 46-52. (in Chinese)
- [29] LI D Z, CHEN X W, HONG S H, et al. FSCIL-SEI: Few-shot class-incremental learning approach for specific emitter identification[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 2504914.
- [30] 张立民, 谭凯文, 闫文君, 等. 基于持续学习和联合特征提取的特定辐射源识别[J]. 电子与信息学报, 2023, 45(1): 308-316.  
ZHANG L M, TAN K W, YAN W J, et al. Specific emitter identification based on continuous learning and joint feature extraction[J]. Journal of Electronics & Information Technology, 2023, 45(1): 308-316. (in Chinese)
- [31] HUA M Y, ZHANG Y B, ZHANG Q Y, et al. KG-IBL: Knowledge graph driven incremental broad learning for few-shot specific emitter identification[J]. IEEE Transactions on Information Forensics and Security, 2024, 19: 10016-10028.
- [32] 李健, 刘欢, 李艳秋, 等. 基于THGS算法优化ResNet-18模型的图像识别[J]. 吉林大学学报(工学版), 2025, 55(5): 1629-1637.  
LI J, LIU H, LI Y Q, et al. Image recognition research on optimizing ResNet-18 model based on THGS algorithm[J]. Journal of Jilin University (Engineering and Technology Edition), 2025, 55(5): 1629-1637. (in Chinese)
- [33] ZHAO D X, HUANG K J, LIU H, et al. Innovative specific emitter identification with self-supervised and incremental learning[J]. IEEE Transactions on Cognitive Communications and Networking, 2026, 12: 2724-2736.
- [34] SHEN J H, AIN Q T, LIU Y H, et al. GTAT: Empowering graph neural networks with cross attention[J]. Scientific Reports, 2025, 15: 4760.
- [35] MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(86): 2579-2605.


#### 作者简介



**赵东兴** 男, 1997年9月出生于浙江省义乌市. 现为国防科技大学电子对抗学院博士研究生. 主要研究方向为通信辐射源个体识别、增量学习、扩散模型及信号处理.  
E-mail: zhaodongxing17@nudt.edu.cn



**刘辉** 男, 1983年11月出生于安徽省阜阳市. 2011年毕业于原解放军电子工程学院. 现为国防科技大学副教授、硕士生导师. 主要研究方向为通信对抗、智能信息处理.  
E-mail: liuhui17c@nudt.edu.cn



**黄科举** 男, 1994年4月出生于山西省运城市. 2022年毕业于国防科技大学电子对抗学院. 现为国防科技大学讲师. 主要研究方向为智能信号处理.  
E-mail: huangkeju@nudt.edu.cn



**杨俊安** 男, 1965年10月出生于安徽省巢湖市. 2003年毕业于中国科学技术大学. 现为国防科技大学教授、博士生导师. 主要研究方向为通信对抗、智能信息处理.  
E-mail: yangjunan17@nudt.edu.cn