

基于迁移与自监督学习的小样本射频指纹识别教学研究

关曼玉¹ 简蕊² 李慢² 刘雯秀² 李广博^{2*}

(1. 淮北理工学院经济与管理学院, 安徽 淮北 235000, 2. 淮北理工学院电子与信息工程学院, 安徽 淮北 235000)

摘要: 人工智能是让机器学习人类行为并模拟人类智能的学科, 应用广泛且对社会发展至关重要, 而人工智能教学对于帮助学生理解抽象知识、深刻领悟原理至关重要。基于迁移学习与自监督对比学习的小样本射频指纹识别展开研究。工作从两方面开展: 一是讲解迁移学习、对比学习如 BYOL 自监督框架、小样本学习的理论与应用; 二是通过实验可视化结果验证方法可行性, 该方法在小样本场景下表现较好。为人工智能教学提供了完整的理论与实践方案, 有助于提升教学效果, 对人工智能未来教学具有重要意义。

关键词: 迁移学习; 对比学习; 小样本学习; 射频指纹识别; BYOL 自监督框架

基金项目: 安徽省教育厅自然科学研究项目(重大)(2024AH040217); 省级质量工程-教学研究项目(2023jyxm1009; 2023xjz1ts117; 2023sdx145); 基于人工智能下的家禽康养与疾病预警技术研究(S202413620055); 基于自监督学习与对抗增强的小样本信号的智能感知研究(2025SK019); 基于深度学习的生猪识别与康养研究(S202513620083); 安徽省智慧农业技术与装备重点实验室开放基金(AEC2026016; AEC2025009)

DOI: doi.org/10.65436/hssj.v1i6.39

当前, 人工智能作为当前科技革命的核心驱动力, 正以多方位深度重塑各领域的研究范式, 拓宽应用边界, 其引领性技术突破对解决复杂现实问题展现出前所未有的关键价值^[1]。人工智能现已纳入我国高校电子信息、计算机、自动化等专业的核心课程体系, 但其教学过程仍面临三重挑战: 一是理论与实践脱节, 多数课程聚焦算法原理的数学推导, 缺乏与实际应用场景的深度结合, 导致学生仅会机械化计算, 不会自主使用; 二是交叉领域理解薄弱, 人工智能与通信、医疗等领域的交叉应用, 要求学生具备跨学科知识整合能力, 但传统教学多局限于单一学科视角, 学生难以构建完整的逻辑步骤; 三是抽象概念具象化难, 缺乏直观的呈现方式, 学生仅能记忆定义, 无法理解其在解决实际问题中的作用。本文聚焦人工智能领域中三类极具实用价值的技术方向, 即迁移学习、对比学习与小样本学习进行展开。其中迁移学习是将模型在源域上学习到的知识与特征, 迁移到另一个相关的目标域中, 达到减少训练成本的目的。对比学习通过构建“对比”关系, 让模型深度挖掘到与“类别属性”强相关的判别性特征, 增强模型对不同类别目标的区分能力, 提升分类精度。小样本学习作为迁移学习的延伸与强化, 是一种克服数据稀缺挑战的机器学习, 通过将源领域预训练知识迁移到目标领域, 并利用目标领域极少量标注样本即可实现模型的快速适配与鲁棒泛化。

基于迁移学习与自监督对比学习的小样本射频指纹识别, 在实际应用场景中面临的场景核心难点主要是在数据少、任务新的情况下, 如何让模型像人一样“学会灵活迁移”? 既要解决“数据少”导致的模型训练不充分、泛化能力弱的问题, 又要处理“新旧知识怎么结合”的矛盾^[2]。为了在人工智能的教学中让学生直观理解这一技术的原理、深刻领悟解决问题的逻辑。相关工作通过以下两方面进行展开:

(1) 理论讲解和实际应用:

¹ **作者简介:** 关曼玉 (1998—), 女, 安徽淮北, 硕士, 助教。研究方向: 人工智能与大数据;

简蕊 (2004—), 女, 安徽蚌埠人, 本科生。研究方向: 人工智能与信号识别;

李慢 (2005—), 女, 安徽池州人, 本科生。研究方向: 人工智能;

刘雯秀 (2005—), 女, 安徽滁州人, 本科生。研究方向: 人工智能;

李广博 (1997—), 男, 安徽淮北人, 讲师, 博士。研究方向: 人工智能、智能信号感知、模式识别、计算机视觉等。

通讯作者: 李广博

理论讲解部分，围绕迁移学习、对比学习和小样本学习展开。先明确三者的关联，以对比学习强化特征学习、迁移学习实现知识复用、小样本学习适配数据稀缺场景，再深入拆解预训练阶段的理论原理：在预训练阶段引入对比学习，通过融合 BYOL 自监督框架与对抗增强技术，结合样本空间几何变换与特征空间扰动的“双域增强”策略，扩大数据多样性，提升模型在不同辐射源数据下的泛化能力，训练出强大的特征提取器，微调阶段使用预训练的特征提取器，在少量标签数据即可训练出性能强大的射频指纹识别网络。其中 BYOL 自监督框架的优势突出：其一，无负样本依赖，能有效应对小样本场景中负样本稀缺难题；其二，采用非对称更新方式，使目标网络参数保持相对稳定，可避免在线网络因噪声样本引发参数震荡，进而提升特征泛化能力；其三，预测器具有矫正作用，能降低投影器输出特征与目标特征的分布差异，助力在线网络更好地学习目标网络的特征表示。

实际应用部分：将迁移学习与自监督对比学习应用于小样本射频指纹识别，该方法提供强大的特征提取能力，旨在从根本上解决传统深度学习对大量标注数据的依赖问题。此外，将这三类技术与射频指纹识别结合，不仅让学生掌握技术的原理，更能培养发散思维，为后续复杂交叉领域的学习奠定基础。

(2) 实验验证：

为验证基于迁移学习与自监督对比学习的小样本射频指纹识别方法可行性，实验验证部分围绕损失图、准确率图、箱线图、TSNE 图等可视化结果展开并进行深度分析，以多维度呈现方法的有效性。损失图聚焦模型训练过程中损失值的动态下降趋势，反映不同损失函数对参数优化的导向，直观展示模型学习效率；准确率图针对小样本场景，清晰呈现模型性能随训练迭代的提升过程，验证“预训练-微调”流程对有限样本的适配效果；箱线图是用于分析数据分布特征与稳定性的工具，通过箱线图的四分位数范围、中位数位置及异常值数量，直观对比所提基于迁移学习与自监督对比学习的小样本射频指纹识别方法与传统小样本识别方的稳定性差异；TSNE 图通过高维射频指纹特征映射到二维空间，实现特征分布可视化，展示不同模型的特征聚合性与区分度，验证迁移学习和自监督学习对特征提取的强化作用。

一、理论讲解和实际应用

迁移学习与自监督对比学习的小样本射频指纹的框架如图 1 所示，该框架包含预训练与微调两个核心阶段，两阶段衔接紧密，共同支撑小样本射频指纹的高效识别。

在微调阶段，一方面借助目标任务的少量标记样本，另一方面以预训练获得的通用特征表示为基础，通过编码器捕捉目标射频信号的关键差异、提取适配目标的专用特征，投影器对特征进行变换以优化分布、强化区分度，结合交叉熵损失函数执行监督微调过程。此过程通过预训练阶段学习的通用知识迁移至特定射频指纹有标签任务场景，使模型能够自适应特定标记射频指纹数据集的任务特性，最终实现小样本射频指纹数据集的高精度识别。




图 1 小样本射频指纹识别流程图

预训练过程，使用未标记数据集结合辅助数据集中的样本，采用传统的数据增强方式与对抗增强^[3]（Adv-Aug）结合的“双域增强”策略，旨在让模型学习射频信号的通用特征，而非仅适配源域特定任务。

在射频指纹识别中通过对原始射频信号样本进行角度旋转、水平或垂直翻转几何变换扩充数据集^[4]，在不

改变信号本质特征的前提下增加样本多样性，减少模型过拟合以增强泛化能力，在迁移学习框架中，其与对抗增强结合形成“双域增强”为预训练阶段提供数据支撑，助力训练强大的特征提取器。

对抗增强是通过特征偏移量变换信号并反向映射，生成与输入张量 x 形状相同的随机扰动 r ，可增强模型抵抗扰动的能力。对抗增强技术通过特征提取网络（下文 ResNet-RF 中的编码器）计算张量 x 和 $x+r$ 的特征表示并将其输入编码器 f_θ 。生成 $z = f_\theta(x)$ 和 $z^* = f_\theta(x+r)$ 两个特征，以找到使 D （距离度量用均方误差表示）最大化的扰动 r ：

$$r_A := \underset{r: \|r\|_2 \leq \varepsilon}{\operatorname{argmax}} D(f_\theta(x), f_\theta(x+r)) \quad (1)$$

其中 $r_A = 1$ 为扰动限制因子， ε 为限制因子用来对抗扰动。受虚拟对抗训练（VAT）^[5]启发，沿梯度方向迭代更新扰动以逼近 r ，在迭代次数设为 1 次（SA2SEI 模型）的基础上增加到 10 次（Our 模型），进一步逼近最大化的扰动 r 。

利用对抗增强模型生成两个增强视图 $v = t(x)$ 和 $v' = t'(x)$ 。自监督学习框架由在线网络（含编码器 f_θ 、投影器 h_θ 、预测器 q_θ ）和目标网络（含编码器 f_ξ 、投影器 h_θ ）构成，通过前向传播获得输出

$p = q_\theta(g_\theta(f_\theta(v)))$ 和 $s' = g_\xi(f_\xi(v'))$ ，经 L_2 归一化后计算均方误差损失函数，可表示为：

$$L_{mse} = \|\bar{p} - \bar{s}'\|_2^2 = 2 - 2 \cdot \frac{\langle p, s' \rangle}{\|p\|_2 \cdot \|s'\|_2} \quad (2)$$

其中 $\tilde{L}_{mse}$ 表示使用 p 和 s' 定义的损失函数。

$$\bar{p} = \frac{p}{\|p\|_2} \quad (3)$$

$$\bar{s}' = \frac{s'}{\|s'\|_2} \quad (4)$$

在线网络通过最小化 $\tilde{L}_{mse}$ 更新参数 ξ ，目标网络按衰减率 τ 进行非对称更新其更新过程为：

$$\xi \leftarrow \tau \xi + (1 - \tau) \theta \quad (5)$$

微调阶段输入两种数据：一是预训练阶段经数据对抗增强、特征学习后，用知识迁移的方式学习模型形成的通用特征；二是目标样本的少量标记数据 $\mathcal{Y}$ 。预训练学习的通用知识，为微调提供基础，让模型无需从零学习。

标记样本先输入编码器 f_θ ，借助预训练阶段优化的网络结构，提取适配目标数据的专用特征。由于预训练已学习射频信号的通用模式，编码器可快速识别目标任务的关键信号差异。提取的特征再传入投影器 h_θ ，其作用是对特征做进一步变换，让特征分布更适配分类需求，同时强化特征区分度。

基于投影器输出的特征，结合交叉熵损失构建优化目标，反向传播调整编码器 f_θ 、投影器 h_θ 的参数。此过程中，预训练的通用知识在少量标记样本约束下适配迁移，保留通用特征提取能力的同时，让模型对目标任务的射频指纹标记数据更敏感。

通过多次迭代，模型逐步收敛。微调后，编码器与投影器的参数不是通用场景适配，而是精准匹配目标样本的标记射频指纹数据特性，实现模型在小样本标记数据下，对特定射频指纹的高精度识别能力。

微调阶段的损失函数如下：

$$L_{sl} = -E \left\{ \log \left[\frac{e^{u(y)}}{\sum_{c=1}^C e^{u(c)}} \right] \right\} \quad (6)$$

二、神经网络

基于迁移学习与自监督对比学习的小样本射频指纹识别使用的神经网络为：一维残差卷积神经网络（ResNet-RF）。ResNet-RF 是 ResNet 变体，核心优势在于残差学习机制，能直接处理复数射频指纹数据的深度学习模型。ResNet-RF 利用深度卷积神经网络强大的分层特征学习能力，自动从原始与预处理后的 I/Q 时序数据中提取判别性的设备固有硬件特征，引入残差学习机制有效解决了深层网络训练中的梯度消失和退化问题，从而捕获到更复杂、抽象且具有高分度度的射频指纹模式，该网络有助于提取高质量的 RFF 特征^[6]。

表 1 展示了一维卷积神经网络（ResNet-RF）各模块的结构与层数：编码器包含 1 层一维卷积、一维批量归一化层、ReLU 激活函数、最大池化层，以及 8 层 ResidualBlock 残差块层，每个残差块层包含两个卷积层、两个一维批量归一化层、跳连层。1 层自适应平均池化层、展平层以及 1 层 Linear（1024）、ReLU 激活函数；投影器由 1 层 Linear（512）、一维批量归一化、ReLU 激活函数和 1 层 Linear（128）组成；预测器同样由 1 层 Linear（512）、一维批量归一化、ReLU 激活函数和 1 层 Linear（128）组成；分类器则为 1 层 Linear（C）。这些模块结构与层数的设计，分别用于特征提取、特征转换与压缩、特征预测及分类。

表 1 ResNet-RF 神经网络的结构

模块	结构	层数
编码器	Conv1d + BatchNorm1d + ReLU + MaxPool1d	1
	ResidualBlock	8
	AdaptiveAvgPool1d(1) + Flatten()	1
	Linear（1024）+ ReLU	1
投影器	Linear(512) + BatchNorm1d + ReLU	1
	Linear(128)	1
预测器	Linear(512) + BatchNorm1d + ReLU	1
	Linear(128)	1
分类器	Linear(C)	1

三、实验环境和参数

SA2SEI 中的模型基于 PyTorch 开发，依托的硬件环境是 13th Gen Intel (R) Core (TM) i9-13900HX（2.20 GHz）的电脑处理器，配备 16.0 GB 内存、1T 存储，8GB 的 4060 显卡，系统是 Windows 11。实验在公开数据集 DWi-Fi^[7]上开展，DWi-Fi 无线网络 Wi-Fi 数据集是采集 16 台 USRP X310 发射机无线电的空中传输，发射机与接收机间距 62 英尺。详细信息和模拟参数如表 2 所示。

表 2 模拟参数

参数	预训练	微调
样本维度	2×4,800	2×4,800
D _{Wi-Fi} 中的类别数量	10	6
D _{Wi-Fi} 中每类的样本数量	1000	{5, 10, 15, 20, 25, 30}
最大轮次	300	300
批次大小	256	128
学习率	0.001	0.001

四、实验分析

实验分析是验证基于迁移学习与自监督对比学习的小样本射频指纹识别方法有效性的核心环节，也是人工智能教学中连接理论与实践的关键纽带。通过对损失图、准确率图、箱线图、TSNE 图四类可视化结果进行深度拆解，不仅量化方法的性能优势，更能将“双域增强”、“BYOL 框架”、“预训练-微调流程”等抽象技术原理转化为可感知的实验现象，帮助学生建立“理论假设-实验验证-结论推导”的科学思维。以下从四类图表的实验现象、技术逻辑与教学价值三方面展开详细分析。

(一) 损失图

模型预训练损失曲线如图 3-a 是 Our 模型预训练损失图，横坐标 (Epoch) 表示训练轮次，纵坐标 (Loss) 表示损失值，反映模型预测结果与真实值的误差，值越小性能越好。从曲线趋势来看，训练集前期 Epoch 小于 50 时呈现快速下降趋势，从初始的高损失值迅速降至 0.5 以下，这一阶段的快速下降并源于预训练阶段“双域增强”策略的有效支撑。一方面，几何变换在不改变射频信号本质硬件特征的前提下，为模型提供了丰富的“相似样本”，使模型能快速捕捉到射频信号固有频率特性；另一方面，对抗增强通过生成最大化扰动的特征样本，迫使模型学习信号的“鲁棒特征”，两类增强方式共同扩大了数据多样性，让模型在训练初期就能高效迭代参数，快速降低预测误差。后期 Epoch 大于 50 时收敛至 0.38 左右，且始终保持稳定无明显波动，这一现象与 BYOL 自监督框架的“非对称更新”机制密切相关。BYOL 的目标网络通过衰减率缓慢更新参数，保持了特征表示的稳定性，避免了在线网络因噪声样本引发的参数震荡；同时，预测器对投影器输出特征的矫正作用，降低了特征分布差异，使在线网络能持续学习目标网络的优质特征表示，最终实现损失稳定收敛。更关键的是，训练集与验证集损失高度重合，说明模型能快速学习到训练数据规律。验证集损失与训练集损失趋势一致且后期重合度高，说明模型未过拟合，训练稳定性好，泛化能力达标。

(二) 准确率图

准确率图 3-b 与表 3 共同构成了小样本场景下模型性能的“量化对比标尺”。实验选取三类具有代表性的模型进行对照：无迁移学 FineZero 模型、迁移学习迭代 1 次的 SA2SEI 模型、迁移学习迭代 10 次的 Our 模型，通过分析不同“样本数量”下的准确率变化，清晰呈现迁移学习与自监督对比学习的技术价值，也为学生理解“小样本学习的核心痛点与解决路径”提供了数据支撑。

表 3 中的 FineZero 是未引入迁移学习的模型，使用迁移学习在对抗增强中沿梯度方向迭代更新扰动，迭代次数设为 1 次为 SA2SEI 模型，10 次为 Our 模型。图 3-b 是不同模型识别准确率，随 Shot 增加，FineZero 准确率从 41.21% 增加到 60.19%，持续提升但识别准确率较低。表明该模型依赖大量样本，小样本时精度小于 60.19%，说明无预训练知识迁移时，模型难以从稀缺样本中提取有效特征；Shot=30 时准确率仅 60.19%，反映模型特征学习能力弱，无法突破原始数据局限难以运用在小样本场景。

表 3 和图 3-b 是不同模型识别准确率，SA2SEI 模型是已有的用于小样本射频指纹识别的模型，模型虽引入迁移学习，但对抗增强的扰动迭代次数仅为 1 次，其准确率整体稳定在 83.4% 到 86.82% 之间，Shot=30 时准确率微降，该模型整体稳定但提升乏力。说明 SA2SEI 模型特征学习浅，迁移学习未充分优化，导致样本量增加时，模型无法挖掘新特征。Shot=30 时精度微降，说明模型对大规模样本分布变化敏感，小样本任务中表现较稳定但有一定提升空间。

表 3 和图 3-b 的 Our 模型基于迁移学习与自监督对比学习的小样本射频指纹识别模型，在小样本场景下展现出显著的性能优：Shot=5 时准确率已达 95.45%，Shot=25 时达峰值 96.44%，Shot=30 时微降至 95.26%，小样本识别准确率精准，跨样本量持续优化。Shot=5 时比 SA2SEI 高 12.05%，进一步说明 Our 模型“迁移学习+自监督”在稀缺样本中也能提取关键特征。Shot 增加时，精度持续优化，说明模型可挖掘样本增量信息，突破 SA2SEI 的精度瓶颈；Shot=30 时微降但仍保持 95% 左右，反映模型对样本分布变化容忍度高，小样本任务中识别精准且稳定。这一优势源于三大组件的协同作用：其一，10 次对抗增强迭代使扰动充分逼近最大化，模型能学习到更鲁棒的射频指纹特征；其二，BYOL 自监督框架通过无负样本依赖、非对称更新与预测器矫正，强化了特征的泛化能力，避免了参数震荡；其三，“预训练-微调”流程实现了通用知识向目标任务的高效迁移，预训练阶段学习的射频信号通用模式，为微调阶段提供了坚实基础，即使仅 5 个标注样本，模型也能快速适配目标任务，提取专用特征。

在教学场景中，Our 模型的准确率曲线是“理论落地”的最佳例证：学生能通过对三类模型的准确率差异，清晰看到“迁移学习+监督对比学习”如何一步步突破小样本的局限。从 FineZero 模型的“无法学习”，到 SA2SEI 模型的“部分学习”，再到 Our 模型的“充分学习”，每一步性能提升都对应着明确的技术改进，将抽象的“技术协同”概念转化为可量化的实验结果。

(三) 箱线图

图 3-c 是 Our 箱线模型在不同 Shot 下呈现出“箱体紧凑、须线短、异常点极少”的特征。如 Shot=5 时中位数近 95%，数据集中在 90-97% 区间；Shot=30 时分布更窄。说明跨样本量预测稳定，结果波动极小，模型效果好。这一现象的核心原因在于模型特征提取的稳定性：双域增强提供了多样且高质量的训练样本，使模型学到的射

频指纹特征具有高度一致性。无论输入的小样本来自哪个批次，模型都能稳定识别其固有特征，因此预测准确率的波动极小；同时，BYOL 框架的非对称更新保证了参数优化的平稳性，避免了因样本波动导致的预测结果大幅偏离。在教学中，这一箱线图能让学生直观理解“鲁棒性”的具体表现：一个鲁棒的模型，其预测结果不会因样本的微小变化而剧烈波动，而是始终保持在较高水平，这对于射频指纹识别等实际应用至关重要，若模型鲁棒性差，轻微的信号干扰就可能致识别错误，引发安全风险。

图 3-d 是 SA2SEI 模型的箱线图呈现出“箱体分散、须线长、异常点多”的特征，Shot=5 时准确率低至 75%，Shot=10 时数据跨度超 15%。反映预训练迭代不足时，模型对小样本敏感，鲁棒性差，易受样本波动干扰，模型效果一般。

表 3 不同模型的识别准确率

模型	5-shot	10-shot	15-shot	20-shot	25-shot	30-shot
FineZero	41.21%	49.5%	50.5%	51.01%	55.12%	60.19%
SA2SEI	83.4%	86.42%	86.33%	86.37%	86.82%	85.97%
Our	95.45%	95.85%	95.4%	95.97%	96.44%	95.26%

(四) TSNE 图

射频指纹特征属于高维数据，人类无法直接感知其分布规律，而 TSNE 技术能将高维特征降维至二维空间，通过“特征簇”的形态直观展示模型的特征提取效果。本实验中三类模型的 TSNE 图，为学生理解“迁移学习与自监督对比学习如何强化特征区分度”提供了最直观的视觉依据。

图 2 中无迁移的 FineZero 图的特征簇紧凑，但依赖原始数据分布，小样本泛化易失效；迁移学习的 SA2SEI 模型迁移不足，特征簇离散、边界模糊如紫色簇分散，说明迁移学习未充分优化，特征聚合性差；迁移学习 Our 模型迁移充分，特征簇相对紧凑、分离清晰，验证了迁移学习和自监督模型强化了特征区分度。这一特征分布，是双域增强、BYOL 框架与预训练-微调流程协同作用的结果：双域增强提供了多样的特征视角，帮助模型捕捉通用特征；BYOL 框架强化了特征的泛化与矫正，使同类特征更统一；预训练-微调流程实现了通用知识向目标任务的迁移，使不同类特征的区分度更强。在教学中，这一 TSNE 图是“抽象特征具象化”的最佳案例。学生无需理解高维特征的数学原理，仅通过观察特征簇的形态，就能明白“迁移学习与自监督对比学习如何让特征更好用，从而将“特征聚合性”“区分度”等抽象概念转化为可感知的视觉认知。




图 2 TSNE 图




图3 模型实验结果图（图a为Our模型预训练损失图；图b为不同模型识别准确率；图c为Our模型箱线图；图d为SA2SEI模型箱线图）

五、结语

在人工智能教学中，抽象的算法原理与复杂的技术逻辑往往成为学生理解的难点，尤其在射频指纹识别这类交叉了通信技术与机器学习的领域，传统教学模式难以让学生将理论与实际应用深度结合。本次以基于迁移学习与自监督对比学习的小样本射频指纹识别为主题的课程，精准锁定这一痛点，通过原理讲解与实验分析相结合的方式，为学生构建了从理论到实践的完整学习路径，不仅贴合人工智能学科的教学规律，更在实际教学中展现出较强的可行性。

原理讲解部分遵循由浅入深、循序渐进的认知规律，为学生搭建了层层递进的知识框架，有效化解了跨学科知识的理解障碍。从射频指纹识别的基础概念及传统技术的局限性切入，逐步过渡到深度学习在该领域的优势与小样本场景的核心挑战，再聚焦于迁移学习“预训练-微调”流程、双域增强策略、损失函数设计逻辑及跨源数据适配等核心原理。通过可视化框架图直观呈现预训练与微调的模块联动，结合公式推导与逻辑拆解，将抽象的“特征泛化”“知识迁移”等概念转化为可理解的过程，帮助学生逐层突破小样本泛化困境、双域增强协同机制等学习难点，为后续实验分析奠定理论基础。

在小样本射频指纹识别教学中，采用理论讲解与实验可视化分析相结合的方式，通过损失图、准确率图、箱型图、TSNE图将抽象理论具象化：损失图动态呈现训练时损失值下降过程，帮助学生看懂损失函数对参数优化的方向；准确率图清晰展示小样本场景下模型从“预训练”到“微调”的性能提升，验证流程对少样本的适配性，解答小样本场景的设计原理；箱型图通过不同样本量下准确率分布，让学生感知模型鲁棒性，理解小样本时预测稳定性；TSNE图把高维特征降维成散点，直观呈现双域增强让特征更聚拢的方法和跨源数据对齐的方法，清晰的展示协同策略、异构缓解等抽象原理。

更重要的是，这种“理论讲解先行、实验验证跟进”的教学逻辑，并非简单的“先讲后看”，而是形成了“理论假设→实验验证→结论深化”的闭环认知。通过可视化拆解复杂理论，先讲原理搭建知识框架，再用实验结果补充细节，帮助学生在实践中对知识的理解和对核心难点的把握。有效解决抽象概念难以理解的问题，贴合认知规律与学习路径，实现了理论认知与实践感知相结合的教学方法。

综上，本次基于小样本射频指纹识别的人工智能教学实践，不仅为“迁移学习、对比学习、小样本学习”的教学提供了完整的理论与实验方案，更探索出一种适用于人工智能交叉领域教学的有效路径：通过“递进式理论讲解”搭建知识框架，用“可视化实验分析”具象化抽象概念，最终实现“理论认知与实践感知”的深度融合。这种方法不仅能帮助学生突破人工智能交叉领域的理解难点，更能培养其解决实际问题的工程思维与科学素养。对于未来的人工智能教学而言，这一实践具有重要的参考价值，在人工智能与各领域深度融合的背景下，唯有打破学科壁垒、强化理论与实践的关联，才能让学生真正掌握人工智能技术的核心逻辑，成长为兼具理论基础与实践能力的复合型人才，为人工智能技术的创新应用与社会发展提供坚实的人才支撑。

参考文献：

- [1] 李广博, 臧宇祺, 闫佳乐等. 新时代人工智能专业质量提升探索[J]. 社会科学前沿, 2024,13(7):665-

671.<https://doi.org/10.12677/ass.2024.137645>

- [2] 黄科举.数据驱动与知识引导相结合的通信辐射源个体识别技术研究[D].国防科技大学, 2022.DOI: 10.27052/d.cnki.gzjgu.2022.000093.
- [3] LIU Chao et al., "Overcoming Data Limitations:A Few-Shot Specific Emitter Identification Method Using Self-Supervised Learning and Adversarial Augmentation," in IEEE Transactions on Information Forensics and Security, vol.19,pp.500513,2024,doi:10.1109/TIFS.2023.3324394.
- [4] 桂冠,陶梦圆,王诚,等.面向特定辐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(03):1-16.
- [5] T. Miyato, S.-I. Maeda, M. Koyama, and S. Ishii, "Virtual adversarial training: A regularization method for supervised and semi-supervised learning," IEEE Trans. Pattern Anal. Mach. Intell., vol. 41, no. 8,pp. 1979–1993, Aug. 2019.
- [6] 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.
- [7] Y. Tu et al., "Large-scale real-world radio signal recognition with deep learning," Chin. J. Aeronaut., vol. 35, no. 9, pp. 35–48, Sep. 2022

Research on AI Teaching for Few-Shot Radio Frequency Fingerprint Recognition Based on Transfer and Self-Supervised Learning

Guan Manyu¹, Jian Rui², Li Man², Liu Wenxiu², Li Guangbo²

(¹ College of Economics and Management, Huaibei Institute of Technology, Huaibei 235000, China

² College of Electronic and Information Engineering, Huaibei Institute of Technology, Huaibei 235000, China)

Abstract:Artificial intelligence is a discipline that enables machines to learn human behaviors and simulate human intelligence. It has a wide range of applications and is crucial to social development. Artificial intelligence teaching is essential for helping students understand abstract knowledge and deeply comprehend principles. This paper conducts research by taking few-shot radio frequency fingerprint recognition based on transfer learning and self-supervised contrastive learning as an example. The work is carried out from two aspects: first, explaining the theories and applications of transfer learning, contrastive learning such as the BYOL self-supervised framework, and few-shot learning; second, verifying the feasibility of the method through experimental visualization results, which shows good performance in few-shot scenarios. This paper provides a complete theoretical and practical scheme for artificial intelligence teaching, which is helpful to improve teaching effects and is of great significance to future teaching.

Keywords: Transfer learning; Contrastive learning; Few-shot learning; Radio frequency fingerprint identification; BYOL self-supervised framework