

## 多路径对比学习的超宽带雷达非视距人体行为识别方法

钟晓玲<sup>①</sup> 周俊霖<sup>\*①</sup> 贾勇<sup>\*①②</sup> 祝庆曦<sup>①</sup> 姚光乐<sup>①</sup> 易诗<sup>①</sup>

<sup>①</sup>(成都理工大学 成都 610059)

<sup>②</sup>(电子科技大学长三角研究院(衢州) 衢州 324000)

**摘要:** 基于多径利用雷达的非视距人体目标行为识别技术在城市作战、智能驾驶、应急救援等领域具有重要的应用价值, 现有研究通常基于监督式深度学习框架, 存在严重依赖大规模标注样本、抗噪性能有限的问题。为此, 该文将多路径传播视作多视角观测信息通道, 通过路径分离和时频分析构造等效多视角的人体行为时频谱图, 进一步提出物理信息嵌入的多路径对比网络(MuPhyCoNet), 一方面将不同路径的多视角时频谱图作为天然的对比学习多路正样本输入, 支撑模型自主学习挖掘行为特征, 无需依赖大量人工标注; 另一方面, 引入观测项与预测项两类物理约束并设计物理一致性损失。观测项直接从原始时频谱图计算物理量差别, 预测项由投影头回归的物理参数与观测值对齐以验证网络所学物理特性; 二者合并, 使模型在保持判别能力的同时, 提高对噪声和建模误差的鲁棒性。该文在采用超宽带步进变频连续波雷达自采的非视距人体行为数据集(6类动作、共19500张时频谱图)上, 采用“自监督预训练+下游分类器”的策略进行了评估。实验结果表明: 在10%标注率设置下, MuPhyCoNet的分类准确率为94.32%, 较MoCo v2的72.19%提升了22.13%, 同时表现出更优的抗噪性能。

**关键词:** 物理引导对比学习; 多径; 自监督学习; SFCW 雷达; 微多普勒; 人体行为识别

中图分类号: TN957.51

文献标识码: A

文章编号: 2095-283X(2026)x-0001-17

DOI: 10.12000/JR25241

CSTR: 32380.14.JR25241

**引用格式:** 钟晓玲, 周俊霖, 贾勇, 等. 多路径对比学习的超宽带雷达非视距人体行为识别方法[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR25241.

**Reference format:** ZHONG Xiaoling, ZHOU Junlin, JIA Yong, *et al.* Multipath contrastive learning for non-line-of-sight human activity recognition using an ultrawideband radar[J]. *Journal of Radars*, in press. doi: 10.12000/JR25241.

## Multipath Contrastive Learning for Non-line-of-sight Human Activity Recognition Using an Ultrawideband Radar

ZHONG Xiaoling<sup>①</sup> ZHOU Junlin<sup>\*①</sup> JIA Yong<sup>\*①②</sup> ZHU Qingxi<sup>①</sup>  
YAO Guangle<sup>①</sup> YI Shi<sup>①</sup>

<sup>①</sup>(Chengdu University of Technology, Chengdu 610059, China)

<sup>②</sup>(Yangtze Delta Region Institute (Quzhou), University of Electronic Science and Technology of China, Quzhou 324000, China)

收稿日期: 2025-11-18; 改回日期: 2026-03-19; 网络出版: 2026-xx-xx

\*通信作者: 周俊霖 2634480674@qq.com; 贾勇 jiaiyong2014@cdut.edu.cn

\*Corresponding Authors: ZHOU Junlin, 2634480674@qq.com; JIA Yong, jiaiyong2014@cdut.edu.cn

基金项目: 中国高校产学研创新基金(2024HY023), 四川省科技计划项目(24NSFSC0498, 2024YFFK0417), 四川省特殊环境机器人重点实验室开放基金项目(24kftk02), 成都理工大学“AI 研究基金”(2025AI019), 成都理工大学研究生科研创新计划(2025BJCX-LS047)

Foundation Items: China University-Industry-Research Innovation Fund (2024HY023), Sichuan Province Science and Technology Program (24NSFSC0498, 2024YFFK0417), Open Fund of Key Laboratory of Special-Environment Robotics, Sichuan Province (24kftk02), AI Research Fund of Chengdu University of Technology (2025AI019), Graduate Scientific Research and Innovation Program of Chengdu University of Technology (2025BJCX-LS047)

责任编辑: 郭世盛 Corresponding Editor: GUO Shisheng

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License

(<https://creativecommons.org/licenses/by/4.0/>)

**Abstract:** Non-Line-of-Sight (NLOS) human activity recognition using multipath-assisted radar has significant potential applications in urban warfare, autonomous driving, and emergency rescue. Existing studies typically rely on supervised deep learning frameworks, which require large labeled datasets and exhibit limited robustness to noise. To address these limitations, this study treats different propagation paths as multiview observational channels. Through path separation and Time-Frequency (T-F) analysis, we construct equivalent multiview T-F spectrograms of human activities. Furthermore, we propose a multipath physics-embedded contrastive network (MuPhyCoNet). In this framework, multiview spectrograms from different propagation paths serve as inherent positive pairs for contrastive learning, enabling the model to extract discriminative features without extensive manual labeling. Moreover, we introduce two categories of physical constraints—observational and predictive, together with a physical consistency loss. The observational constraints compute physical divergence directly from the raw spectrograms, while the predictive constraints align the physical parameters regressed by the projection head with their observed counterparts to verify the learned physical characteristics. The integration of both constraints enhances the model’s robustness to noise and modeling errors while preserving high discriminative capability. We evaluate the proposed method on a self-collected NLOS human activity dataset (comprising 6 action classes and 19,500 spectrograms) acquired using an ultrawideband stepped-frequency continuous wave radar, following a “self-supervised pretraining + downstream classifier” strategy. Experimental results demonstrate that MuPhyCoNet achieves a classification accuracy of 94.32% with only 10% labeling data, outperforming MoCo v2 (72.19%) by 22.13 percentage points while exhibiting superior noise robustness.

**Key words:** Physics-informed contrastive learning; Multipath; Self-supervised learning; SFCW radar; Micro-Doppler; Human activity recognition

## 1 引言

基于多径利用的雷达非视距(Non-Line-of-Sight, NLOS)目标探测技术通过对墙角衍射及墙面反射等回波路径的分选与整合<sup>[1]</sup>, 实现了对遮蔽区域内目标的检测、定位、跟踪与识别<sup>[2-4]</sup>, 在城市作战、智慧交通与应急救援等场景中展现出重要的应用价值<sup>[1,5,6]</sup>。虽然目前研究仍主要聚焦于遮蔽目标的存在性检测与定位<sup>[1,2,4]</sup>, 但深度学习驱动的人体行为识别(Human Activity Recognition, HAR)已成为该领域最具前景的研究热点之一<sup>[7-9]</sup>。同时, 在更广泛的雷达感知研究中, 端到端建模范式也在快速发展。例如, RadarFormer直接面向雷达时空序列进行端到端人体感知建模<sup>[10]</sup>, RFMamba则通过状态空间模型(State Space Model, SSM)进一步提升了对长序列射频信号的特征提取效率<sup>[11]</sup>, 为非视距行为识别提供了新的演进思路。

与视距(Line-of-Sight, LOS)场景类似, NLOS环境下的雷达人体行为识别同样基于人体运动对回波的多普勒调制效应<sup>[12,13]</sup>。不同之处在于, 电磁波经由不同传播路径(反射、衍射)到达目标时, 入射角度的差异使得NLOS雷达能够获取目标行为的多视角观测信息<sup>[8,14,15]</sup>。由多径效应产生的这种多视角特性, 含有更完备的目标运动描述, 从而为提升复杂环境下的行为识别精度奠定了物理基础<sup>[7,16]</sup>。例如, 文献<sup>[8]</sup>提出了一种利用雷达传感器网络的多径分量进行人体行为识别的方法, 通过多个雷达节

点捕获不同传播路径的信息, 实现目标的多视角观测, 从而在监督学习设置下提高识别准确率; 文献<sup>[7]</sup>使用多径融合技术在NLOS拐角环境中进行人体行为识别, 该方法通过提取衍射与反射路径的特征并进行融合, 构建综合表征, 在NLOS场景下提升了识别性能; 文献<sup>[17]</sup>利用毫米波雷达的多径回波信息进行NLOS人体行为检测, 通过特征扩展技术整合不同传播路径的信息, 增强监督学习框架下的检测能力; 文献<sup>[18]</sup>采用多种雷达谱图进行NLOS人体行为识别, 通过分析多径信号的时频特征进行活动分类, 验证了该方法在监督学习条件下的有效性; 文献<sup>[14]</sup>利用多径效应提供的多视角信息, 提出了一种方向无关(Direction-Independent)的识别方法, 增强了模型在各种场景下的鲁棒性; 文献<sup>[16]</sup>使用4D成像雷达进行NLOS人体姿态重建和行为识别, 利用多径信息在复杂环境中重建姿态并识别人体活动。此外, 无线信号人体姿态估计方向已有系统性综述, 可为相关任务设置与评测提供参考<sup>[19]</sup>。然而, 上述方法均局限于监督学习范式。尽管相较于多径抑制方法, 此类方法在识别性能上取得了较大提升, 但仍面临诸多挑战: (1)标注依赖性高。深度模型往往需要数千乃至数万标注样本, 而实际应用中不同场景、不同用户的数据标注成本高昂且耗时; (2)抗噪鲁棒性不足。在真实NLOS环境中, 墙体反射衰减、多径干扰与环境噪声使信号质量有所下降, 而面对训练数据分布之

外的未知样本时，监督学习模型的鲁棒性表现通常较差<sup>[20]</sup>。

近年来，自监督学习方法被视为缓解标注依赖的有效途径。在雷达信号处理领域中，常用的自监督学习方法有掩码学习和对比学习两大类。掩码学习机制通过对输入信号进行随机遮挡，要求模型根据未遮挡部分的上下文关联来预测被掩码区域。这一过程强化了模型对信号本质结构的感知，有助于提取鲁棒的表征<sup>[21,22]</sup>。对比学习则通过构造正负样本对，最大化正样本对之间的一致性，最小化负样本对之间的一致性。正如图像领域能通过对比学习提取具有视角不变性的特征一样<sup>[23,24]</sup>，本文也利用前文提及的源于多径效应的多视角观测信息来学习人体行为的语义表征。之所以在两类自监督范式中优先选择对比学习，是因为本文任务在物理机制层面具备“同一语义、不同观测”的多视角特性：多径分选后来自不同传播路径的时频谱图可直接构造语义一致的多路正样本输入，从而显式学习跨路径(跨视角)的不变判别表征，并避免过度依赖数据增强。相比之下，掩码学习更偏向重建式目标，其优化往往依赖稳定且可预测的重建内容；在NLOS时频谱图存在较强噪声扰动、多径衰减差异与局部畸变时，掩码重建容易倾向学习“能量填补与纹理补全”等与下游分类不完全一致的表征。基于上述考虑，本文采用对比学习作为自监督骨架。不过，仅使用对比学习的方法本质上仍停留在“纯数据驱动”层面，缺乏对雷达信号物理机制的显式约束，导致学习到的表征可能与真实值存在偏差，且可能违反基本物理规律，限制了模型的可解释性、面对噪声的鲁棒性以及分布外数据上的泛化能力。

为缓解“纯数据驱动”导致的物理一致性缺失问题，物理引导学习(Physics-Informed Learning)<sup>[25]</sup>主张以损失约束或结构归纳偏置的形式将物理先验显式嵌入学习过程。其典型代表，物理引导神经网络(Physics-Informed Neural Networks, PINNs)<sup>[26]</sup>通过在损失函数中引入偏微分方程残余项，已在流体力学、材料科学等领域取得成功应用。在雷达感知领域，已有工作尝试利用物理先验进行约束<sup>[27]</sup>，但现有研究多聚焦于监督学习框架下的单点约束，与自监督对比学习的深度融合极为有限<sup>[28]</sup>，尤其在NLOS人体行为识别任务中尚属空白。

为此，本文基于动量对比学习(Momentum Contrast, MoCo)架构<sup>[29,30]</sup>，设计了物理信息嵌入的多路径对比网络(Multipath Physics-Embedded Contrast Network, MuPhyCoNet)，如图1所示。本网络将自监督对比学习、多径回波产生的多视角

观测和雷达物理先验统一纳入同一框架，以在有限标注与噪声干扰条件下获得更稳健且可解释的表征。需要说明的是，本文所称“物理信息嵌入”主要体现在损失层面：通过物理观测一致性项与物理预测一致性项对表征学习进行显式约束，并配套设置物理预测投影头以回归可解释物理量，从而将物理先验注入对比学习过程，而非额外引入一个独立的物理建模网络模块。具体而言本文进行了两项关键创新。

(1) 显式多视角信息利用：将多径分选后的多路时频谱图作为正样本对输入网络，取代对比学习中使用数据增强从单个样本得到两个正视图的方法，以获取更贴合实际的表征。

(2) 物理一致性约束：设计双分支物理投影头从骨干特征预测若干类物理参数，并将这些预测与基于观测时频谱图计算的物理量对齐(构成物理预测损失)；同时在时频域对若干统计特征进行直接匹配(构成物理观测损失)。两类约束联合构成总物理损失，既可验证模型学到的物理特征，又为训练提供稳健且可解释的监督信号，从而增强物理约束的可靠性。

## 2 多路径回波分离与表征对象生成

延续引言中“多径可等效为多视角观测”的观点，本节给出从物理先验出发的预处理与表征对象生成流程：首先在非视距(NLOS)环境下抑制强静态杂波，随后按传播路径进行分离，并在各分离后的路径周围构造等效的“多视图”样本，从而为后续的对比学习提供语义一致且几何多样的观测对象<sup>[1,15]</sup>。

### 2.1 基于两脉冲对消的静态杂波抑制

在室内NLOS场景中，墙体与固定设施产生的强静态散射主导了回波能量谱，若不加处理将直接掩蔽弱小的人体微动成分。为此，本文采用两脉冲对消(Two-Pulse Canceller, TPC)这一经典动目标指示方法<sup>[31]</sup>来抑制静态杂波。TPC通过计算相邻脉冲周期回波的差分实现高通滤波，在抑制静态分量的同时保留人体微动信号。由于TPC作用于慢时间维度且对距离无选择性，因此适用于所有距离单元中的多径信号。在本文“L”型拐角NLOS数据中，人体微动导致的非静态分量在各条可提取的显著路径上均存在，故本文对所有距离单元统一执行TPC预处理，以全面提升各路径的信杂比。

### 2.2 多路径分离与有效路径提取

如图2所示，设经脉冲压缩和两脉冲对消预处理

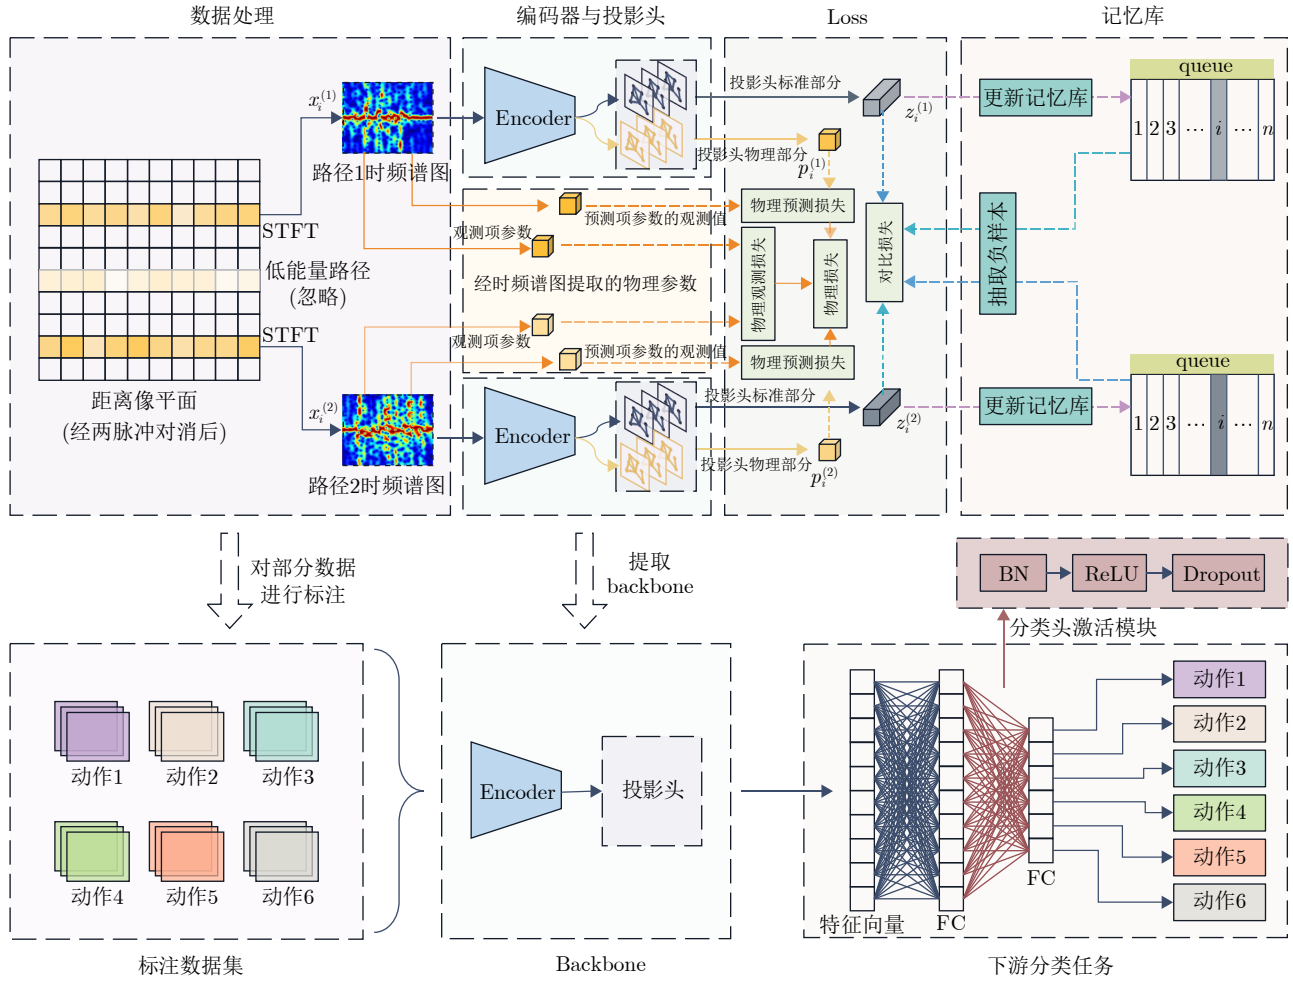


图1 基于多径效应的对比学习雷达行为识别框架示意图

Fig. 1 Framework schematic of multipath-effect-based contrastive learning for radar activity recognition

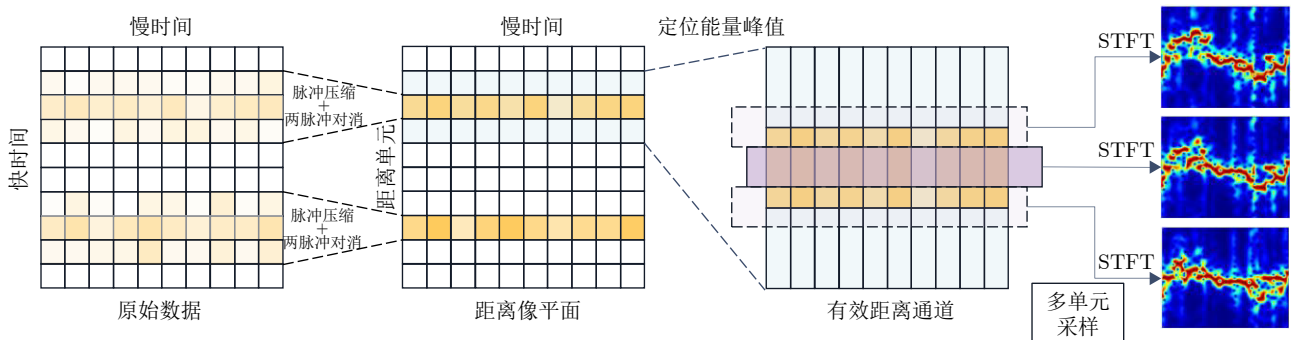


图2 数据处理过程示意图

Fig. 2 Data processing procedure diagram

理后, 原始回波被转换为距离-慢时间数据矩阵  $\mathbf{S}$ 。由于人体躯干、四肢等不同散射中心的空间延展性, 其回波能量会分散在多个距离单元中<sup>[7,32]</sup>。为准确定位各传播路径对应的主导距离单元<sup>[33-35]</sup>, 本文结合L型拐角的几何先验进行能量寻峰。

理论上, 本场景存在3条候选主路径: 双衍射路径  $P_{11}$ 、双反射路径  $P_{22}$  及衍射-反射组合路径  $P_{12}$  (其具体几何含义与场景设置将在4.1节详述)。

本文首先沿慢时间维度计算各距离单元的累积能量  $E(r)$ :

$$E(r) = \sum_t |\mathbf{S}(r, t)|^2 \quad (1)$$

随后, 根据雷达与墙体的相对几何关系, 估算各候选路径  $p$  对应的理论传播距离区间  $[R_{p,\min}, R_{p,\max}]$ 。结合雷达距离分辨率  $\Delta R$  (见表1), 将该物理区间映射为距离单元搜索窗口  $\Omega_p$ 。在该搜索窗

表 1 雷达系统参数

Tab. 1 Radar system parameters

参数	数值
起始频率	1.6 GHz
截止频率	2.2 GHz
带宽	600 MHz
步进频率	2 MHz
频点数 $K$	301
频点持续时间	100 $\mu$ s
距离分辨率	0.25 m
最大不模糊距离	75 m

口内，选取能量最大处作为该路径的主导距离单元  $r_p^*$ ：

$$r_p^* = \arg \max_{r \in \Omega_p} E(r) \quad (2)$$

这种划分窗口的寻峰策略有效降低了不同路径能量峰相互干扰造成的误选风险。此外，为确保输入信号质量，本文采用自适应筛选策略：将3条路径对应的峰值能量  $E(r_p^*)$  进行降序排列，仅保留能量最强的两条路径构成有效路径集  $\mathcal{P}_{\text{valid}}$ 。此举有效滤除了因墙体严重遮挡或高阶反射导致的极弱信号路径。

### 2.3 多单元采样与时频谱图生成

为充分捕获目标散射的空间延展性并增强数据多样性，本文提出一种多单元空间采样策略。对于每条有效路径  $p \in \mathcal{P}_{\text{valid}}$ ，以其主导距离单元  $r_p^*$  为中心，在距离向  $[-w, w]$  范围内以步进  $s$  提取共计  $2w/s + 1$  个采样单元。

在本文实验设置中，采样半窗跨度  $w = 30$ ，步进  $s = 5$ ，即围绕单条路径提取共计13个采样单元。需要指出的是，距离像由频域回波经  $N$  点快速傅里叶逆变换(Inverse Fast Fourier Transform, IFFT)得到；为细化距离栅格，实现时对未采样频点进行了补零对齐。其距离栅格间隔(Grid spacing)可表示为  $d_r = R_{\text{max}}/N$ ，其中  $R_{\text{max}}$  为最大探测距离。在本文参数设置下 ( $R_{\text{max}} = 75$  m,  $N = 4096$ )，计算得  $d_r \approx 0.0183$  m。由此可知，该采样策略在距离维度的物理覆盖范围约为1.10 m (即  $60 \times d_r$ )，相邻采样点的物理间隔约为0.09 m (即  $5 \times d_r$ )。需要注意的是，由于补零操作，栅格间隔  $d_r$  不同于由带宽决定的理论距离分辨率 ( $\Delta R = 0.25$  m)。本文设置使采样窗覆盖了多个分辨单元，旨在充分容纳NLOS多径场景下由肢体动作引起的径向漂移与能量扩展。对于不同配置的雷达系统，也可通过调整覆盖长度与采样步进实现算法的迁移。

接着，对每一个采样单元  $r_i$  的慢时间序列执行短时傅里叶变换(Short-Time Fourier Transform, STFT)，生成反映肢体微动特性的时频谱图  $X_{p,i}(m, k)$ ：

$$X_{p,i}(m, k) = \left| \sum_n \mathbf{S}(r_i, n) W(n - m) e^{-j2\pi kn/N_f} \right|^2 \quad (3)$$

其中， $W$ 为窗函数， $m$ 与 $k$ 分别为时间帧与频率索引。该采样策略显著丰富了各传播路径的观测维度，生成的多张谱图虽在距离向上存在微小的几何偏置，但仍保持着高度的运动语义一致性。这从物理层面天然满足了对比学习中“同一动作、不同观测”的正样本构造原则。

最后需要说明的是，图2中展示的STFT时频谱图主要用于帮助读者直观理解上述数据处理流程与样本时频结构。该示例属于可视化质量较高的正常样本，未经过任何人工增强或特殊后处理；本文所有实验样本均严格执行上述同一套预处理链路。为避免单一样例造成误解，图3中进一步补充展示了不同动作类别、不同路径下的时频谱图样例。

## 3 多路径对比学习行为识别网络构建

### 3.1 对比学习网络

本文设计了物理信息嵌入的多路径对比网络 MuPhyCoNet，在保持MoCo动量对比学习优势的同时，将多径效应产生的多视角信息与雷达物理一致性显式融入表征学习过程，从而获得更具可解释性与鲁棒性的表征。MuPhyCoNet的设计基于以下核心理念：(1)通过大规模内存队列提供充足的判别性信息，能够有效抵抗物理约束引入的表征平滑化效应；(2)优化正样本构造策略。利用多径分选后的多视角时频谱图构造正样本对，以替代传统的数据增强方式，从而通过挖掘多径互补性学习视角不变的语义表征。具体而言，本文提出跨路径正样本构造：在批次(batch)中，对同一多视图样本的不同路径分别进行随机采样，生成对应的查询项  $q$  与键值项  $k$ 。通过这种跨路径的正样本构造方式，有效增强了模型对视角变化的鲁棒性。(3)将经由网络的物理预测损失与不经过网络的物理观测损失相结合，并与对比损失自适应加权融合，在保持判别性的同时提升表征的物理合理性与抗噪鲁棒性。MuPhyCoNet的核心结构与损失计算过程如图4所示。

架构上，MuPhyCoNet包含主编码器(query encoder)和动量编码器(key encoder)两个分支，二者采用相同的网络结构(ResNet-18骨干)<sup>[36]</sup>，移除分类头，但参数独立维护。其网络结构配置汇总见

表2。动量编码器参数通过式(4)以动量方式从主编码器更新:

$$\theta_k \leftarrow m\theta_k + (1-m)\theta_q \quad (4)$$

其中, 动量系数  $m$  在实现中取固定值  $m = 0.999$ , 动量编码器为主编码器的深拷贝且参数冻结, 仅通过指数移动平均进行更新, 以稳定表征学习并减少

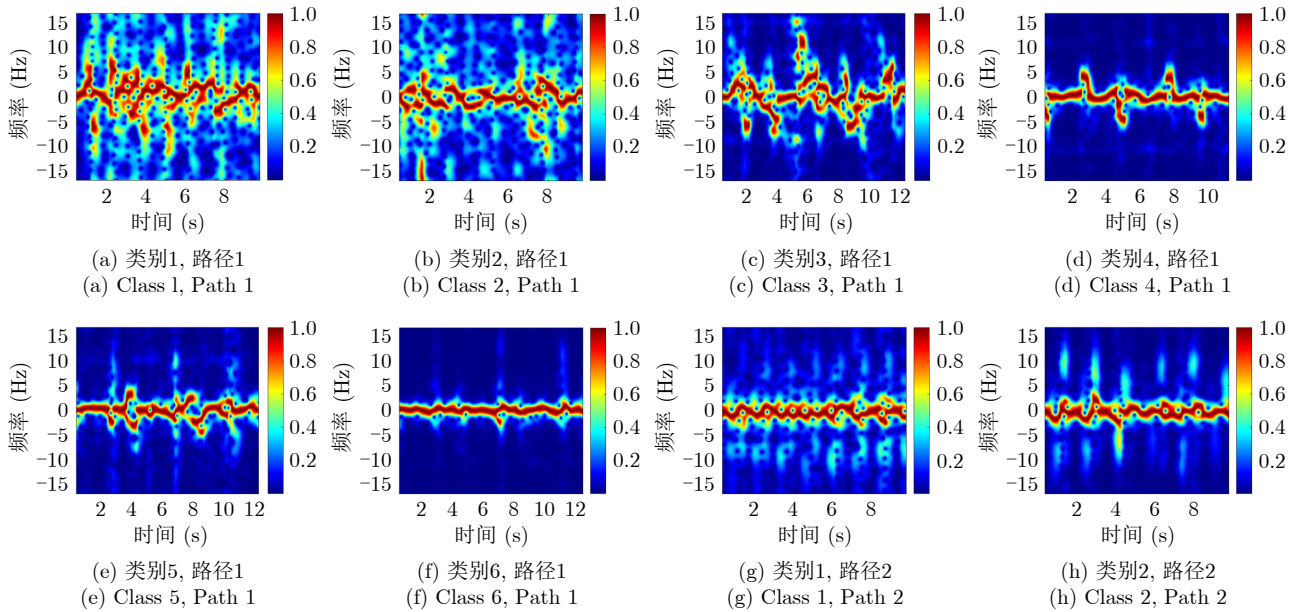


图3 不同动作不同路径对应的时频谱图样例

Fig. 3 Example of time-frequency spectrograms for different actions and different paths

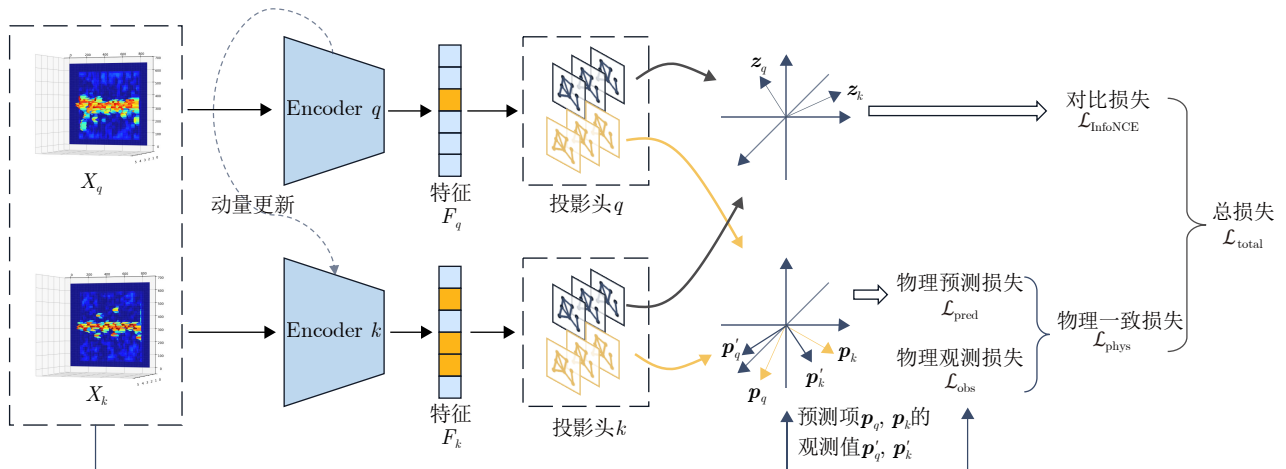


图4 物理引导注入的对比学习网络MuPhyCoNet

Fig. 4 Physics-information-injected contrastive learning network MuPhyCoNet

表2 MuPhyCoNet网络结构

Tab. 2 MuPhyCoNet architecture summary

阶段	输出尺寸	配置
输入	$H \times W \times C$	时频谱图输入( $C = 3$ )
Backbone	-	ResNet-18(标准配置, 移除分类头)
全局池化	$1 \times 1 \times 512$	全局平均池化(Global Average Pooling, GAP)
语义投影头	128	Linear(512, 2048) $\rightarrow$ BN $\rightarrow$ ReLU $\rightarrow$ Linear(2048, 128)
物理预测头	64	Linear(512, 1024) $\rightarrow$ BN $\rightarrow$ ReLU $\rightarrow$ Linear(1024, 64)
特征融合	128	拼接(128维语义 + 64维物理) $\rightarrow$ Linear(192, 128) $\rightarrow$ BN
对比学习设置	-	MoCo双编码器框架( $m = 0.999$ ; 队列 $K = 4096$ ; 温度 $\tau = 0.1$ ); 跨路径正样本构造(跨路径采样 $q/k$ 视图)

梯度震荡<sup>[29]</sup>。延续MoCo的设计，本文采用内存队列(memory bank)维护负样本，队列大小为4096，该队列存储历史负样本以提供充足的判别信息，避免批量内负样本不足导致的模式坍塌<sup>[29]</sup>，从而在有限批量大小(batch size)下提供充足的对比信息。为将物理先验注入表征学习，本文设计了跨越网络的物理观测损失，并在主编码器端设计了双分支投影头以得到物理预测损失，双分支投影头的形式为

$$\begin{cases} \mathbf{z} = g_{\text{sem}}(\mathbf{h}) & (\text{语义分支}) \\ \mathbf{p} = g_{\text{phy}}(\mathbf{h}) & (\text{物理参数分支}) \end{cases} \quad (5)$$

其中， $\mathbf{h}$ 为主编码器输出的表征， $\mathbf{p} = [v, t_c, f_d, \dots]$ 为预测的物理参数向量(速度、时间质心、频率变化率等)。语义分支直接将 $\mathbf{h}$ 映射至对比空间；物理参数分支基于编码器的输出特征计算参数并与观测数据(即时频谱图)直接计算的物理参数进行对齐，得到物理预测损失，对于输入网络的两个正样本，对得到的两个预测损失进行等权重合并。对于两个未经过编码器的原始时频谱图，计算其物理参数并进行对齐，得到物理观测损失。最终，物理预测损失与物理观测损失进行合并，形成总的物理一致性损失。这一设计不仅使模型在自监督学习过程中嵌入物理先验，还通过多层次的物理信息约束提升了表征的鲁棒性和可解释性。

### 3.2 损失函数

在自监督预训练阶段，MuPhyCoNet采用归一化温度缩放交叉熵损失(Normalized Temperature-scaled Cross Entropy, NT-Xent)实现InfoNCE损失，并将其与物理一致性损失进行自适应融合。总损失定义为

$$\begin{aligned} \mathcal{L}_{\text{total}} &= \mathcal{L}_{\text{InfoNCE}} + \lambda_t \mathcal{L}_{\text{phys}}, \\ \lambda_t &= \text{EMA}(\sigma(\phi) \cdot \lambda_{\text{max}} \cdot R_{\text{ratio}}, \alpha) \end{aligned} \quad (6)$$

其中，自适应权重系数 $\lambda_t$ 用于动态平衡语义对比项与物理约束项之间的数值差异。 $\sigma(\cdot)$ 为Sigmoid函数， $\phi$ 为网络中可学习的权重参数； $\lambda_{\text{max}}$ 为预设的权重上限(本文取0.1)。特别地， $R_{\text{ratio}}$ 为损失比例对齐因子，其作用是将物理回归损失自动缩放到InfoNCE损失的指定比例(本文设为10%)，从而消除不同任务间固有的数值失配。

实验观测显示，自适应权重 $\lambda_t$ 在训练早期经过短暂波动后，迅速收敛并长期稳定在 $\lambda_{\text{min}} = 0.03$ 附近，在TensorBoard记录中表现为一条准水平直线。这一现象源于物理一致性损失在数值上较高，为了维持预设的10%辅助任务比例， $R_{\text{ratio}}$ 协同指数滑动平均机制自发调低了物理项的增益系数。这种

机制通过平衡物理任务与对比任务，达到引导模型在兼顾物理先验知识的基础上，优先提取对分类具有强区分性的对比特征的目的。基于上述融合框架，总损失函数中的各分量详细定义如下。

InfoNCE损失采用标准的NT-Xent形式：

$$\begin{aligned} \mathcal{L}_{\text{InfoNCE}} &= -\ln \frac{\exp(\text{sim}(\mathbf{q}, \mathbf{k}^+)/\tau)}{\exp(\text{sim}(\mathbf{q}, \mathbf{k}^+)/\tau) + \sum_{i=1}^K \exp(\text{sim}(\mathbf{q}, \mathbf{k}_i^-)/\tau)}, \\ \text{sim}(\mathbf{q}, \mathbf{k}) &= \frac{\mathbf{q}^T \mathbf{k}}{\|\mathbf{q}\| \|\mathbf{k}\|} \end{aligned} \quad (7)$$

其中， $\text{sim}(\cdot, \cdot)$ 为相似度函数， $\tau$ 为温度超参数， $K$ 为内存队列中的负样本数量。

物理一致性损失 $\mathcal{L}_{\text{phys}}$ 由观测损失与预测损失两部分加权组合而成：

$$\mathcal{L}_{\text{phys}} = \sum_{u=1}^6 w_u \mathcal{L}_{\text{obs},u} + \sum_{v=1}^4 w_v \mathcal{L}_{\text{pred},v} \quad (8)$$

其中， $\mathcal{L}_{\text{obs},u}$ 与 $\mathcal{L}_{\text{pred},v}$ 分别表示6项观测损失与4项预测损失， $w_u$ 和 $w_v$ 为对应的权重系数。通过这种两层平衡机制(即子项加权求和与前述 $\lambda_t$ 的整体自适应调节相结合)，本文确保了物理约束始终以“有限强度正则”的形式参与优化。物理观测损失与物理预测损失的各子项具体物理定义如下。

物理观测损失子项：

(1) 质心一致性损失，确保两个正样本视图的频率质心保持一致：

$$\mathcal{L}_{\text{centroid}} = \ell_1(\text{centroid}_1, \text{centroid}_2) \quad (9)$$

其中， $\text{centroid}_{i,t}$ 表示第*i*视图在时刻*t*的频率质心。

(2) 频谱JS散度损失，使用Jensen-Shannon散度量多普勒频谱分布的相似性：

$$\begin{aligned} \mathcal{L}_{\text{spec}} &= \text{JS}(P_1 \| P_2) \\ &= \frac{1}{2} \sum_i \left[ P_1(i) \ln \frac{P_1(i)}{M(i)} + P_2(i) \ln \frac{P_2(i)}{M(i)} \right], \\ M(i) &= \frac{P_1(i) + P_2(i)}{2} \end{aligned} \quad (10)$$

其中， $P_1(i), P_2(i)$ 为两个正样本视图的归一化多普勒频谱分布， $M(i)$ 为其均值； $\text{JS}(P_1 \| P_2)$ 为Jensen-Shannon散度(自然对数)。

(3) 时间-频率平滑性损失，约束信号在时间维度上的频率变化连续性：

$$\begin{aligned} \mathcal{L}_{\text{smooth}} &= \frac{1}{2} \left[ \sum_{t=2}^T (\text{centroid}_{1,t} - \text{centroid}_{1,t-1})^2 \right. \\ &\quad \left. + \sum_{t=2}^T (\text{centroid}_{2,t} - \text{centroid}_{2,t-1})^2 \right] \end{aligned} \quad (11)$$

其中,  $\text{centroid}_i$ 表示第*i*视图的整体频率质心。

(4) 谱展宽一致性损失, 确保两个正样本视图的谱分布宽度保持一致:

$$\mathcal{L}_{\text{spread}} = \ell_1(\sigma_1, \sigma_2) = |\sigma_1 - \sigma_2|,$$

$$\sigma = \sqrt{\frac{\sum_k (f_k - \text{centroid})^2 W(f_k)}{\sum_k W(f_k)}},$$

$$W(f_k) = |S(f_k)|^2 \quad (12)$$

其中,  $\sigma$ 为频谱展宽系数, 用于度量谱分布宽度;  $\ell_1(a, b) = |a - b|$ 为L1距离。

(5) 多普勒对称性损失, 约束多普勒频谱的正负频率对称性:

$$\mathcal{L}_{\text{sym}} = \frac{1}{2} \left[ \sum_f |S_1(f) - S_1(-f)| + \sum_f |S_2(f) - S_2(-f)| \right] \quad (13)$$

其中,  $S_1(f), S_2(f)$ 为两视图的时频谱幅度分量(经幅度归一化), 下标1和2分别表示第1视图和第2视图的对应量。

(6) 局部相干损失, 确保时频谱图局部区域的相干性:

$$\mathcal{L}_{\text{local}} = \frac{1}{N} \sum_{\text{patches}} (1 - \cos(\theta_{\text{patch},1}, \theta_{\text{patch},2})) \quad (14)$$

其中,  $\theta_{\text{patch}}$ 为对应块的归一化能量向量(即将块内像素能量展平后归一化得到的向量)。

物理预测损失子项:

(1) 多普勒质心预测损失, 确保预测的速度参数与观测质心一致:

$$\mathcal{L}_{\text{dopp}} = \frac{1}{2} [\ell_1(\text{centroid}_1, v_1) + \ell_1(\text{centroid}_2, v_2)] \quad (15)$$

其中,  $v_1, v_2$ 为投影头回归得到的速度(多普勒参数)。

(2) 时间质心预测损失, 确保预测的时间参数与观测一致:

$$\mathcal{L}_{\text{time}} = \frac{1}{2} [\ell_1(t_{\text{obs},1}, t_{\text{pred},1}) + \ell_1(t_{\text{obs},2}, t_{\text{pred},2})] \quad (16)$$

其中,  $t_{\text{obs}}, t_{\text{pred}}$ 分别为观测与预测的时间质心;  $\Delta f_{\text{obs}}, \Delta f_{\text{pred}}$ 为频率质心平均变化率。

(3) 频率变化率预测损失, 确保预测的频率变化率与观测一致:

$$\mathcal{L}_{\text{freq}} = \frac{1}{2} [\ell_1(\Delta f_{\text{obs},1}, \Delta f_{\text{pred},1}) + \ell_1(\Delta f_{\text{obs},2}, \Delta f_{\text{pred},2})] \quad (17)$$

(4) 参数范围约束损失, 确保预测的物理参数在合理范围内:

$$\mathcal{L}_{\text{bounds}} = \frac{1}{2} \left[ \sum \max(0, |v| - v_{\text{max}}) + \sum \max(0, -t) + \sum \max(0, t - T_{\text{sweep}}) \right] \quad (18)$$

其中,  $W$ 为其功率谱;  $\text{patches}$ 表示局部时频块集合,  $\max(0, \cdot)$ 为超出范围的惩罚项;  $N$ 为时频块总数;  $T$ 为时间帧数;  $v_{\text{max}}, T_{\text{sweep}}$ 来自雷达参数, 分别表示速度上限与单次扫描时长。

上述损失设计不仅将雷达物理先验显式引入训练过程, 而且通过观测层与预测层的双重一致性约束(即物理观测损失 $\mathcal{L}_{\text{obs}}$ 与物理预测损失 $\mathcal{L}_{\text{pred}}$ 的联合作用)对物理信息进行相互验证与强化, 从而提升模型的泛化能力、抗噪鲁棒性与可解释性。

### 3.3 分类器架构设计

在自监督预训练完成后, 本文通过下游任务分类性能评估表征质量: 即冻结骨干网络, 在其端部挂载一个两层MLP分类头进行有监督训练。该设计在保持评估过程轻量化的同时, 通过非线性映射增强了分类判别能力。如图5所示, 分类头采用两层多层感知机(Multi-Layer Perceptron, MLP)结构, 通过批归一化(Batch Normalization, BN)、整流线性单元(Rectified Linear Unit, ReLU)和随机失活(Dropout)(0.5)增强泛化能力, 其表示为

$$\mathbf{h}_1 = \text{Dropout}_{0.5}(\text{ReLU}(\text{BN}(\mathbf{W}_1 \mathbf{z} + \mathbf{b}_1))),$$

$$\hat{\mathbf{y}} = \mathbf{W}_2 \mathbf{h}_1 + \mathbf{b}_2 \quad (19)$$

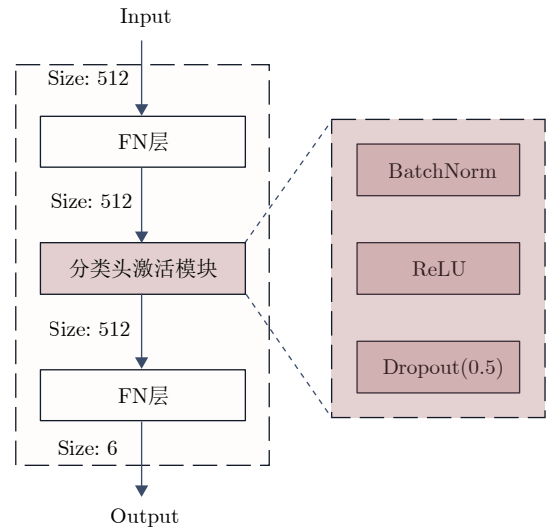


图5 下游分类器结构示意图

Fig. 5 Downstream classifier structure schematic diagram

其中,  $z \in \mathbb{R}^{512}$ , 为骨干网络输出表征,  $W_1 \in \mathbb{R}^{512 \times 512}$ ,  $W_2 \in \mathbb{R}^{C \times 512}$  为权重矩阵,  $C$  为类别数 (本文  $C = 6$ )。该设计在保持轻量级的同时, 通过非线性映射增强分类能力。

#### 4 实验验证与分析

本节详细介绍实验设置: 包括NLOS实验场景与雷达参数、数据集构建及划分策略、模型的训练细节与超参数设定, 并展示不同测试结果与相应分析。

##### 4.1 实验场景设置

本文采用超宽带步进变频连续波雷达(Stepped-Frequency Continuous-Wave, SFCW)采集数据, 设备参数见表1。实验在L型建筑拐角这一典型遮蔽场景中进行: 雷达布置于一侧墙体附近, 目标位于另一侧的非视距(NLOS)区域, 雷达电磁波需经墙角衍射及墙面反射才能到达目标<sup>[4]</sup>。考虑到电磁波经多次反射后信号强度会急剧衰减, 肢体末端等高速运动部位的微多普勒特征(对应较高频率分量)将变得极为微弱<sup>[37]</sup>。这些高频分量对应的雷达散射截面(Radar Cross Section, RCS)本身就较小, 经多径衰减后在时频图上将难以辨识<sup>[1,15]</sup>。因此, 本文仅提取经一次反射或衍射的有效路径, 主要关注如图6所示的3条显著传播路径:  $P_{11}$ (双衍射路径)、 $P_{22}$ (双反射路径)和 $P_{12}$ (衍射-反射组合路径)。

为便于读者量化“目标与雷达之间的几何关系”, 本文以墙角点  $O$  为坐标原点建立平面坐标系, 位置示意图图7: 雷达位于  $(-0.8, -0.75)$ , 原始数据集的目标位置位于  $(1.2, 2.65)$ 。此外, 为覆盖不同目标空间位置(引入不同传播路径长度与

回波强度变化)以检验跨路径策略在跨位置条件下的泛化性, 本文选取6个额外目标位置采集数据:  $(1.2, 3.05), (0.8, 2.65), (1.6, 2.65), (2.2, 2.65), (1.2, 2.25)$  与  $(1.6, 2.25)$ , 并在典型设置(10%标注率)下将其作为跨位置外部测试集进行评估, 得到分类准确率为  $81.3054 \pm 2.2089\%$ 。该结果表明, 所提方法在目标空间位置变化条件下仍具有一定的泛化能力。

需要强调的是, 本文实验主要在单一L型拐角NLOS场景下完成; 在更复杂的传播环境(如T型路口)或不同材质墙体(如高吸收率材料)条件下, 多径衰减与可观测路径集合可能发生变化, 进而导致某些反射类路径(例如  $P_{22}$ )信号极弱甚至难以稳定提取。为应对“第2条强路径缺失”这一情形, 本文方法在流程层面具备自适应退化能力: 首先在路径分离与距离单元选取阶段, 对能量极弱或不稳定的路径进行剔除(见第2节的能量峰值策略与路径筛选描述), 仅保留可观测的主导路径参与建模; 若最终仅剩1条有效路径, MuPhyCoNet将自动退化为单视图对比学习, 跨路径正样本构造不再启用, 正样本对由同一路径内的不同视图增强生成, 物理一致性约束亦可在单路径观测上继续作为有限强度正则参与优化。因此, 本文框架在多路径信息可观测时可获得额外增益, 但并不依赖于固定数量的路径。

##### 4.2 数据集构成

为了在真实的NLOS环境中评估本文网络的性能, 依据第2节所述的多路径回波分离与表征对象生成方法, 在图7所示的NLOS拐角场景中采集并构建了一个包含6类常见人体运动行为的数据集, 具体动作释义见表3。数据集共包含19500张时频谱图, 按8:1:1划分为训练集(15600张)、验证集(1950张)和测试集(1950张)。主要实验采用10%标注率设置: 训练集中仅1560张(每类260张)带标




图6 SFCW雷达回波路径示意图

Fig. 6 SFCW radar echo path schematic diagram




图7 实验场景中的雷达与目标位置示意图

Fig. 7 Radar and target positions in the experimental scenario

表3 数据集动作类别及描述

Tab. 3 Action classes and descriptions in the dataset

类别	动作	描述
1	原地踏步	四肢自然交替运动
2	静止摆臂	手臂前后自然摆动
3	站-坐-起	坐下等待1 s左右再重新站立
4	弯腰捡物	弯腰手臂下垂作捡物状, 然后直立
5	抬手抛物	右手抬过头顶作抛物状后放下, 然后站定
6	来回行走	人在L型走廊非直视区域绕圈走动, 同时手臂摆动

签, 其余作为无标签数据参与自监督预训练。此外, 为评估标注依赖性, 额外进行1%(156张)和100%(15600张)标注率的对比实验。此外, 本文补充说明: 数据采集由5名志愿者参与(身高范围: 166~182 cm; 体重范围: 52~80 kg), 每名志愿者均完成表3中的全部动作类别。

### 4.3 训练细节

本文的实验基于PyTorch和PyTorch Lightning框架实现, 并使用NVIDIA RTX3090 GPU进行加速。训练采用两阶段策略。

第1阶段(自监督预训练, MuPhyCoNet): 使用随机梯度下降(Stochastic Gradient Descent, SGD)优化器<sup>[38]</sup>, 初始学习率 $6 \times 10^{-2}$ , 动量0.9, 权重衰减 $10^{-4}$ , 采用余弦退火学习率调度, 周期 $T_{\max}$ 设为最大迭代次数, 最小学习率 $\eta_{\min} = \max(\eta_0 \cdot 0.1, 10^{-4})$  ( $\eta_0$ 为初始学习率); 动量系数 $m = 0.999$ ; memory bank大小为4096; 温度系数 $\tau = 0.1$ ; 可学习参数 $\phi$ 从0附近初始化, 通过 $\lambda = \sigma(\phi) \cdot \lambda_{\max}$  ( $\lambda_{\max} = 0.1$ )控制物理损失权重。

第2阶段(下游分类器): 冻结骨干网络权重, 仅训练分类头。采用Adam(Adaptive Moment Estimation)优化器, 学习率 $10^{-3}$ , 权重衰减 $10^{-5}$ , 损失函数为交叉熵。使用余弦退火调度, 30个epoch内学习率从初始值衰减至 $10^{-6}$ 。

数据增强方面, 在自监督与监督阶段均使用随机裁剪(对于MuPhyCoNet来说, 数据增强在构造跨路径正样本对后进行)。物理预测损失子项“参数范围约束损失”的参数与表1的SFCW设备一致, 以确保物理一致性项与真实成像链路匹配。

### 4.4 推理开销与部署考量

在推理与部署阶段, 物理参数分支将被整体移除, 仅保留经自监督预训练的骨干网络与轻量化MLP分类器。该分支仅在预训练阶段发挥作用, 用于引入物理一致性约束并提升模型的可解释性, 因此不会增加实际部署时的计算开销。该MLP分类器的参数量约为 $512 \times 512 + 512 + 512 \times C + C \approx 0.266 \text{ M}$  ( $C = 6$ ), 其计算量相对骨干可忽略, 端到端延迟主要由骨干网络主导。具体开销评估如表4所示, 评估设置细节如下: 目标硬件为NVIDIA RTX 5080; batch=1; 仅统计模型推理计算(不含数据加载及预处理); 先进行若干次预运行后重复多次测量, 并报告均值 $\pm$ 标准差与P50/P90; GPU计时采用CUDA events以避免异步误差。

### 4.5 不同标注率下的性能对比

表5列出了不同方法在多种标注率下的分类准确率, 可视化结果如图8所示。为公平对比自监督预训练的有效性, 本文设置两类基线: (1)ResNet-50端到端训练, 直接在标注数据上从零训练完整网络, 代表纯监督学习的性能; (2)ResNet-18(ImageNet预训练骨干, 冻结)+两层MLP。该基线作为对比学习预训练效果的验证(即“预训练有效性”基线), 其评估方法与自监督方法保持一致。对比学习方法包含3组: MoCo v2/PI-MoCo/MuPhyCoNet(本文方法), BYOL/PI-BYOL, SimCLR v2/PI-SimCLR。其中, 各框架的“基础版本”与其对应的“物理一致性(Physics-Informed, PI)版本”在表5中成对呈现, 构成对物理一致性损失的消融对比, 用于验证所引入物理约束的有效性。引入BYOL<sup>[39]</sup>(Bootstrap Your Own Latent, 非对称架构)和SimCLR<sup>[40]</sup>(Simple Contrastive Learning of Representations, 非动量更新负样本策略)旨在验证对比学习在本文NLOS雷达场景下的普遍有效性, 同时便于考察物理约束策略在不同框架上的适用性。PI版本的构建遵循各框架特性: PI-BYOL将物理一致性项仅作用于target网络分支, PI-SimCLR, PI-MoCo和MuPhyCoNet则在主损失中融合物理约束(式(8))。

表4 目标硬件上的模型推理开销评估(仅推理计算, 用于结构开销对照)

Tab. 4 Inference cost on target hardware (inference only, for architecture overhead comparison)

组件/结构	参数量(M)	FLOPs (G)	延迟均值 $\pm$ 标准差(ms)	P50/P90 (ms)
部署推理: 骨干(ResNet-18)	11.18	1.819	2.091 $\pm$ 0.074	2.076 / 2.192
预训练辅助: 物理预测头	1.94	0.002	0.511 $\pm$ 0.073	0.494 / 0.530
预训练结构: 骨干 + 物理预测头	13.12	1.820	2.516 $\pm$ 0.157	2.491 / 2.648

表 5 不同方法在多种标注率下的分类准确率(%)  
Tab. 5 Classification accuracy of different methods under various label rates (%)

方法	样本标注率			
	1%	10%	100%	
基线	ResNet-50(端到端训练)	32.15±0.54	32.12±0.90	31.97±2.87
	ResNet-18(ImageNet权重)+ 分类器	26.19±0.74	28.26±1.21	23.69±1.43
对比学习方法 (骨干: ResNet-18)	<b>MuPhyCoNet</b>	<b>84.24±0.26</b>	<b>94.32±0.13</b>	<b>91.28±0.86</b>
	PI-MoCo	77.44±0.21	84.75±0.88	86.68±0.64
	MoCo v2	71.78±0.08	72.19±1.31	68.91±1.00
	PI-BYOL	81.98±0.44	86.85±0.16	87.54±0.58
	BYOL	82.19±0.41	86.12±0.34	87.59±0.80
	PI-SimCLR	82.02±0.08	88.48±0.08	90.53±0.36
	SimCLR v2	82.34±0.03	87.32±0.43	87.81±0.19

注：表内加粗数值表示相同样本标注率下的最佳准确率。

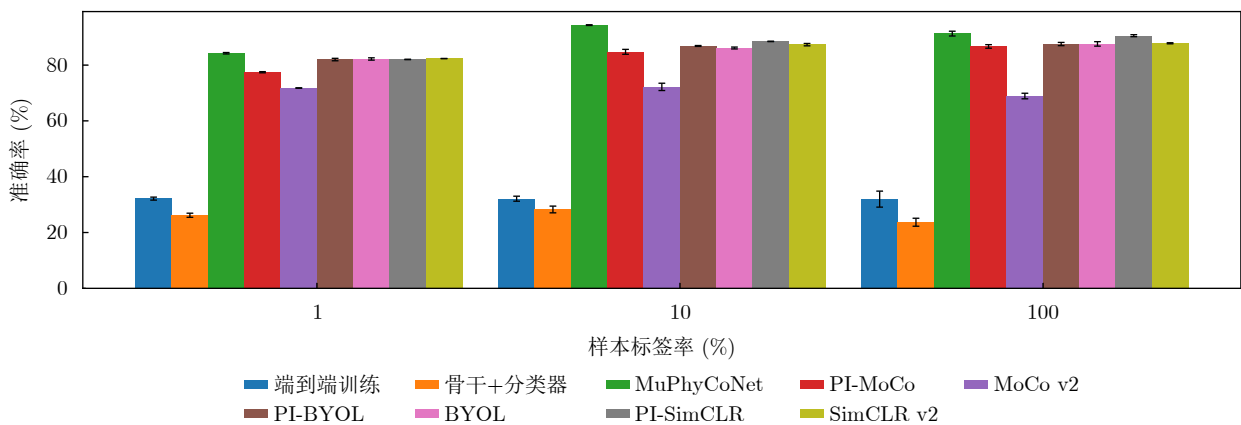


图 8 不同标注率下的分类准确率(分组柱状图)

Fig. 8 Classification accuracy under different label rates (grouped bar chart)

所有对比学习方法均遵循标准两阶段训练策略：先在全无标签数据上进行自监督预训练，随后冻结骨干网络，仅仅用指定比例的标注样本训练分类头。两个基线亦在相同的架构和标注量上执行相同流程(不过不进行自监督预训练)，这样唯一的差异就是是否利用无标签数据，从而直观地量化在标注稀缺情形下自监督学习带来的性能提升。

从表5可以得出以下结论：

(1) 在本实验设置下，所有对比学习方法均优于两类基线。以10%标注率为例，表现最差的对比学习方法MoCo v2(72.19%)比监督预训练迁移基线ResNet-18(ImageNet权重)+MLP分类器(28.26%)高出43.93个百分点、比ResNet-50网络端到端训练(32.12%)高出40.07个百分点。这些结果表明，对比学习预训练能够从大量无标签雷达数据中提取出有效的语义特征，降低对有标签样本的依赖。

(2) 物理一致性带来的增益是普遍的。对比MoCo v2与PI-MoCo, BYOL与PI-BYOL, Sim-

CLR v2与PI-SimCLR, 引入物理一致性损失后, 在10%标注率下准确率分别提升12.56%, 0.73%, 1.16%。这些结果表明, 物理先验通过约束多径观测的一致性与差异性, 有效挖掘了路径间互补信息, 从而改善了表征质量。

(3) 跨路径正样本构造带来的增益。为进一步区分“物理一致性损失”与“跨路径正样本构造”的贡献, 本文同时给出了PI-MoCo(仅引入物理一致性损失, 正样本仍由标准增强构造)与MuPhyCoNet(同时使用跨路径正样本构造与物理一致性损失)的实验结果。可以看到, MuPhyCoNet相对PI-MoCo在1%, 10%, 100%标注率下分别提升6.8, 9.57, 4.60个百分点, 表明在NLOS多径场景中, 跨路径正样本对能够更充分利用“同一动作、不同路径观测”的互补性, 从而进一步提升表征质量。

(4) MuPhyCoNet, PI-MoCo, PI-BYOL与PI-SimCLR的综合对比: 四者均在不同程度上受益于物理一致性约束, 但在“低标注率收益”与“噪声

鲁棒性”上呈现差异。首先,在低标注率(1%, 10%)下, MuPhyCoNet分别达到84.24%与94.32%, 优于PI-MoCo(77.44%, 84.75%), PI-BYOL(81.98%, 86.85%)与PI-SimCLR(82.02%, 88.48%); 其次,在高标注率(100%)下, PI-SimCLR在干净数据上更接近MuPhyCoNet(90.53% vs 91.28%), 但其在加性噪声扰动下鲁棒性明显不足(见表6); 相比之下, PI-BYOL在准确率略低于PI-SimCLR的同时, 在噪声扰动下保持更稳健的下降曲线, 体现了非对称结构对物理约束的兼容性。为便于读者快速对照, 本文在表7对四者在关键设置下的性能进行汇总。

(5) 为了排除监督基线(ResNet-50)在本数据集上表现偏低是由于实现或训练流程问题, 也在公开图像数据集CIFAR-10上进行了验证。取得了与文献报道接近的Top-1准确率(约88.5%, 50 epochs), 由此可基本排除因代码实现或训练流程异常导致性能偏低的可能性。

(6) 进一步地, 为分析物理损失各子项的贡献, 本文补充了物理一致性损失子项的细粒度消融。在MuPhyCoNet的训练步骤下, 逐一将某一子项权重置0以等效移除该约束, 其余设置保持不变, 并在1%, 10%, 100% 3种标注率下评估测试准确率, 结果见表8, 可见在典型设置(10%标注率)下

表 6 在不同加性噪声水平下的分类准确率(%)

Tab. 6 Classification accuracy under different levels of additive noise (%)

方法	无噪声	0.1 (26.4 dB)	0.2 (20.4 dB)	0.3 (16.9 dB)	0.5 (12.5 dB)
MoCo v2	73.23	56.15 (-23.32%)	57.23 (-21.85%)	58.05 (-20.73%)	58.21 (-20.51%)
PI-MoCo	85.74	82.77 (-3.46%)	80.87 (-5.68%)	79.49 (-7.29%)	80.72 (-5.85%)
MuPhyCoNet	94.31	<b>92.77 (-1.63%)</b>	<b>91.54 (-2.94%)</b>	<b>90.82 (-3.70%)</b>	<b>89.13 (-5.49%)</b>
BYOL	85.74	74.87 (-12.68%)	75.08 (-12.43%)	65.74 (-23.33%)	47.90 (-44.13%)
PI-BYOL	86.97	79.03 (-9.13%)	80.26 (-7.71%)	80.26 (-7.71%)	76.97 (-11.50%)
SimCLR v2	87.59	83.13 (-5.09%)	81.90 (-6.50%)	80.97 (-7.56%)	79.49 (-9.25%)
PI-SimCLR	88.41	81.59 (-7.71%)	76.41 (-13.57%)	69.33 (-21.58%)	60.97 (-31.04%)

注: 表内加粗数值表示相同噪声水平下的最佳准确率, 括号内的数值为相较于无噪声准确率的百分比变化。

表 7 MuPhyCoNet, PI-MoCo, PI-BYOL与PI-SimCLR的性能汇总

Tab. 7 Performance summary of MuPhyCoNet, PI-MoCo, PI-BYOL and PI-SimCLR

方法	10%标注率(%)	100%标注率(%)	噪声0.5下降率(%)
MuPhyCoNet	94.32	91.28	5.49
PI-MoCo	84.75	86.68	5.85
PI-BYOL	86.85	87.54	11.50
PI-SimCLR	88.48	90.53	31.04

表 8 物理一致性损失子项的细粒度消融结果(%)

Tab. 8 Fine-grained ablation on the sub-terms of the physics-consistency loss (%)

消融设置(将对应子项权重置 0)	样本标注率		
	1%	10%	100%
基线(全部子项)	88.36	94.92	93.28
$-\mathcal{L}_{\text{centroid}}$ (无质心一致性)	87.95 (-0.46%)	94.00 (-0.97%)	93.54 (0.28%)
$-\mathcal{L}_{\text{spec}}$ (无频谱JS散度)	87.59 (-0.87%)	92.97 (-2.05%)	91.64 (-1.76%)
$-\mathcal{L}_{\text{smooth}}$ (无时频平滑性)	88.77 (0.46%)	91.90 (-3.18%)	92.15 (-1.21%)
$-\mathcal{L}_{\text{spread}}$ (无谱展宽一致性)	88.46 (0.11%)	94.00 (-0.97%)	92.87 (-0.44%)
$-\mathcal{L}_{\text{sym}}$ (无多普勒对称性)	88.92 (0.63%)	93.44 (-1.56%)	91.38 (-2.04%)
$-\mathcal{L}_{\text{local}}$ (无局部相干)	88.10 (-0.29%)	93.79 (-1.19%)	94.21 (1.00%)
$-\mathcal{L}_{\text{dopp}}$ (无多普勒质心预测)	87.79 (-0.65%)	94.56 (-0.38%)	92.87 (-0.44%)
$-\mathcal{L}_{\text{bounds}}$ (无参数范围约束)	90.82 (2.78%)	94.77 (-0.16%)	93.23 (-0.05%)
$-\mathcal{L}_{\text{time}}$ (无时间一致性)	90.62 (2.56%)	94.15 (-0.81%)	91.64 (-1.76%)
$-\mathcal{L}_{\text{freq}}$ (无频率变化率)	87.49 (-0.98%)	93.44 (-1.56%)	91.64 (-1.76%)

注: 括号内的数值为相较于基线准确率的百分比变化。

时间-频率平滑性损失与频谱JS散度损失对网络的贡献最大。为避免自适应权重对消融实验的影响,本组实验中总物理权重系数固定为 $\lambda = 0.1$ ,且各子项权重统一设为 $w_* = 0.1$ ;消融仅通过将目标子项的 $w_*$ 置0实现。

#### 4.6 特征空间可视化分析

为更直观地展现不同对比学习方法的特征表征质量,本文对测试集样本在特征空间中的分布进行可视化。具体采用主成分分析(Principal Component Analysis, PCA)以及统一流形近似投影(Uniform Manifold Approximation and Projection, UMAP)联合降维:首先通过PCA将特征降到固定的主成分数(50维),以降低计算复杂度,再使用UMAP将高维特征映射至二维空间。图9展示了采用ImageNet-18权重的ResNet-18骨干及7种对比学习方法(MuPhyCoNet, MoCo v2, PI-MoCo, SimCLR v2, PI-SimCLR, BYOL, PI-BYOL)在预训练后提取的特征经降维后的二维分布。不同颜色代表不同的行为类别,特征点的聚集程度反映了模型对类内一致性的学习能力,而类间的分离程度则体现了模型的判别能力。

从图9可以观察到,除PI-SimCLR外,添加了物理约束的方法(MuPhyCoNet, PI-MoCo, PI-BYOL)相比于对应的基础方法,都在特征空间中类内

的聚集度有所提高,并且类间的分离度有所上升。这表明物理一致性损失有效地引导模型学习到了更具判别性和鲁棒性的特征表示。

#### 4.7 泛化能力与鲁棒性

本节针对第4节提到的7种对比学习方法,测试它们在典型情况下(样本标注率为10%)对两类变换的鲁棒性:一类为视觉级变换(亮度、对比度与裁剪,检验对预处理差异的敏感性),另一类为雷达物理级变换(如加性噪声),以评估模型在不同类型域变换下的稳定性与泛化性。

如表9所示,这7种模型在亮度、对比度与随机裁剪等视觉级变换下均保持较高的识别准确率,表明模型对可视化预处理差异具有一定鲁棒性。表6和图10进一步展示了加性噪声实验结果,以分析噪声扰动对模型性能的影响,从而给出更具实用意义的鲁棒性结论。噪声强度以标准差 $\sigma \in \{0.1, 0.2, 0.3, 0.5\}$ 表示,对应的信噪比(SNR)分别为26.4, 20.4, 16.9, 12.5 dB。基准测试( $\sigma = 0$ )不添加额外噪声。

从表6及图10可以看出,随着噪声水平增加,各模型准确率均有所下降;但引入物理一致性约束后, MuPhyCoNet, PI-MoCo与PI-BYOL的下降曲线更为平缓。以噪声级别0.5为例, MuPhyCoNet, PI-MoCo与PI-BYOL分别下降5.49%, 5.85%与

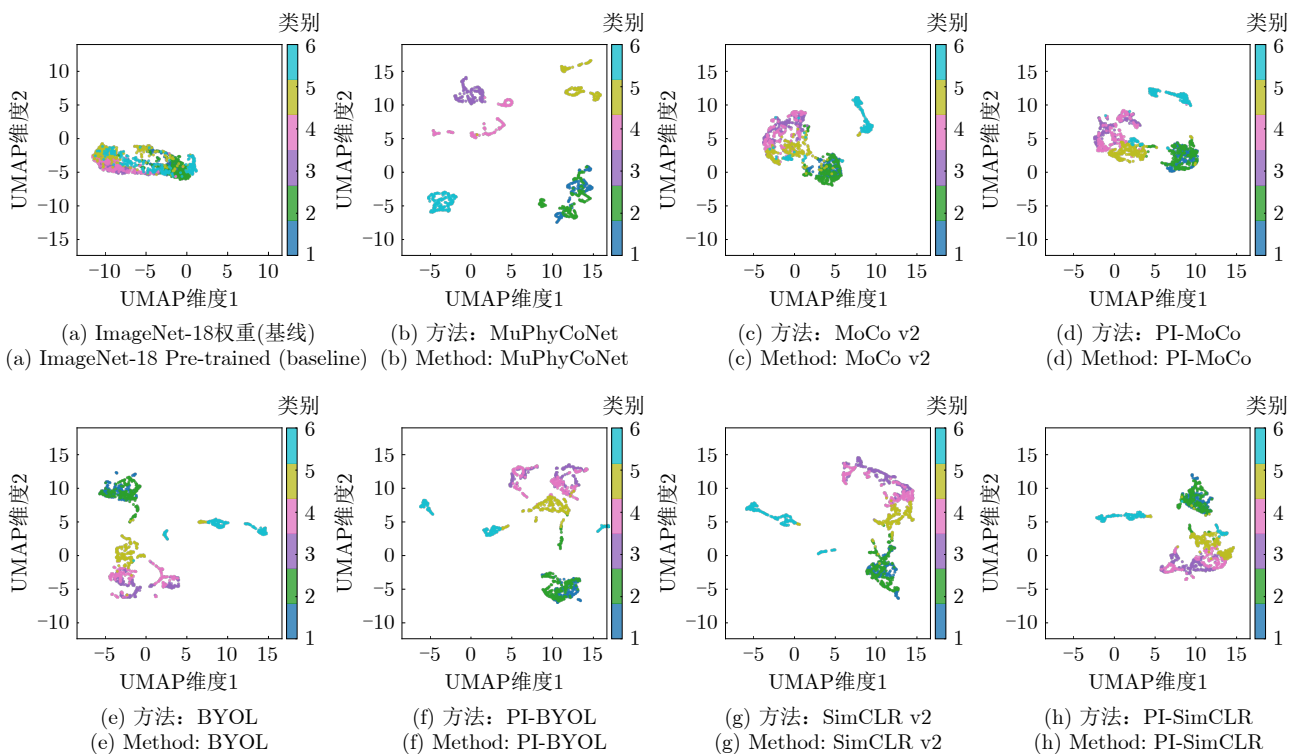


图9 不同对比学习方法的特征空间可视化(PCA联合UMAP降维)

Fig. 9 Feature space visualization of different contrastive learning methods (PCA and UMAP dimensionality reduction)

表9 在不同视觉级变换下的分类准确率(%)  
Tab. 9 Classification accuracy under different visual-level transformations (%)

方法	原始域	亮度变化	对比度变化	随机裁剪
MoCo v2	73.23	72.97 (-0.36%)	72.82 (-0.56%)	74.92 (2.31%)
PI-MoCo	85.74	85.79 (0.06%)	85.54 (-0.23%)	86.36 (0.72%)
MuPhyCoNet	94.31	94.31 (0%)	94.21 (-0.11%)	94.97 (0.70%)
BYOL	85.74	85.79 (0.06%)	85.64 (-0.12%)	87.79 (2.39%)
PI-BYOL	86.97	87.03 (0.07%)	86.97 (0%)	87.74 (0.89%)
SimCLR v2	87.59	87.69 (0.11%)	87.38 (-0.24%)	89.08 (1.70%)
PI-SimCLR	88.41	88.56 (0.17%)	88.41 (0%)	89.95 (1.74%)

注: 括号内的数值为相较于原始域准确率的百分比变化。

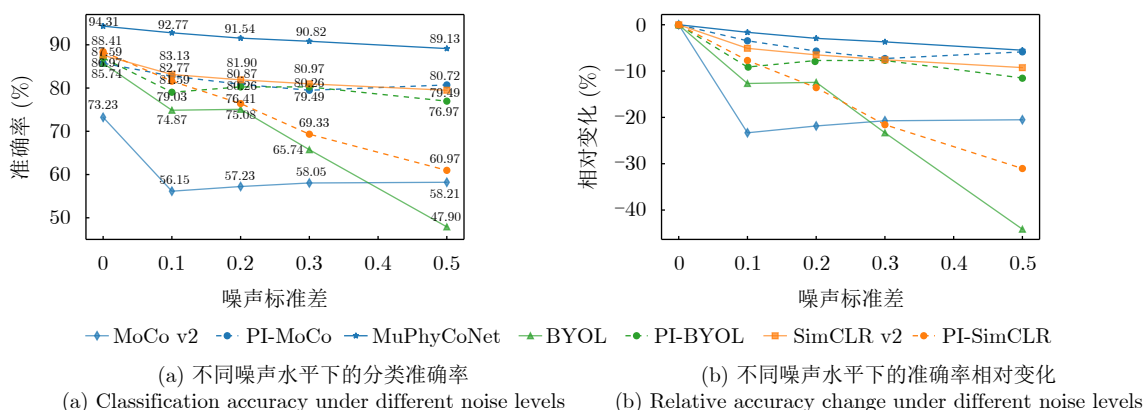


图10 噪声鲁棒性分析

Fig. 10 Noise robustness analysis

11.5%, 而对应基础方法MoCo v2与BYOL分别下降20.51%与44.13%。这表明物理一致性损失能够有效提升物理扰动下的鲁棒性; 同时MuPhyCoNet相较PI-MoCo仍进一步降低了下降幅度, 说明跨路径正样本采样机制在此基础上还能带来额外的鲁棒性增益。

值得注意的是, PI-SimCLR的表现与期望不符: 虽然在干净数据上准确率相比基线SimCLR有所提升, 但噪声鲁棒性反而下降(噪声级别0.5时下降31.04%)。结合对比学习机制的理论分析, 这一看似矛盾的结果可能源于梯度流设计与负样本策略两个相互关联的因素。

(1) 梯度流机制: 物理约束通过降低类内方差提升了Fisher判别比 $J = \text{tr}(\mathbf{S}_B)/\text{tr}(\mathbf{S}_W)$ , 在干净数据上表现更优; 然而, SimCLR采用对称架构, 同一编码器 $f(\cdot; \theta)$ 处理两个增强视图 $x_0, x_1$ , 物理约束损失 $\mathcal{L}_{\text{phys}} = \|\phi_0 - \phi_1\|^2$  (其中,  $\phi_i = \phi(f(x_i; \theta))$  为物理参数)的梯度从两个方向同时回传:

$$\frac{\partial \mathcal{L}_{\text{phys}}}{\partial \theta} = \frac{\partial \mathcal{L}_{\text{phys}}}{\partial \phi_0} \frac{\partial \phi_0}{\partial \theta} + \frac{\partial \mathcal{L}_{\text{phys}}}{\partial \phi_1} \frac{\partial \phi_1}{\partial \theta} \quad (20)$$

这种双向梯度强制可能使网络倾向于压缩不同增强样本间的物理差异, 导致表征空间过度平滑

化, 削弱判别性边界。相比之下, MuPhyCoNet的动量编码器机制通过梯度阻断(key侧参数不接收物理约束梯度)实现梯度解耦, 仅query编码器 $f_q(\cdot; \theta_q)$ 接收物理约束更新, 有助于避免双向梯度冲突; PI-BYOL同样采用非对称结构, 物理约束仅作用于目标网络, 实现单向引导。

(2) 负样本充足性: 在上述梯度机制可能导致的表征平滑化背景下, 负样本数量进一步影响判别性维持能力。SimCLR依赖batch内负样本(本文为128), 而MuPhyCoNet的memory bank(本文为4096)可提供约32倍的负样本多样性。根据InfoNCE损失的判别性信号强度 $\propto \log K$  ( $K$ 为样本数)<sup>[41]</sup>, 充足的负样本有助于维持更鲁棒的决策边界裕度 $\gamma = d_{\text{inter}}/\sqrt{d_{\text{intra}}}$ <sup>[42]</sup>; 而PI-BYOL则无需显式负样本, 通过预测器-目标网络机制规避了该约束。

#### 4.8 混淆矩阵分析

本文方法(MuPhyCoNet)在标注率为10%时的混淆矩阵如图11所示。从混淆矩阵可见, 类别6(来回行走)及类别5(抬手抛物)在对角线处的响应值高于其他位置, 表明该类识别准确率相对较高。这可能与类别6在较长时间内保持连续运动、速度模式




图 11 归一化混淆矩阵

Fig. 11 Normalized confusion matrix

相对稳定，从而形成更清晰的时序演变有关；而类别5的抬手抛物动作幅度(动作范围)更大，使其微多普勒展宽与能量分布更具特征性，因此更易与其他类别区分。

相比之下，类别1(原地踏步)与类别2(静止摆臂)，以及类别3(站-坐-起)与类别4(弯腰捡物)之间存在相对较高的相互误判(对应混淆矩阵的非对角线单元较高)。其中，类别1与类别2的主要差异在于腿部是否运动，其微多普勒模式相近；在多径传播下，能量扩散与多路径叠加可能进一步增加时频特征的重叠度，从而加大区分难度。

## 5 结语

本文针对室内非视距(NLOS)多径场景下的雷达人体行为识别问题，提出了物理信息嵌入的多路径对比网络(MuPhyCoNet)。通过将多路径回波视为多视角观测并在动量对比学习框架中引入物理一致性损失，该方法在标注稀缺和噪声干扰下均表现出了优越性。在包含6类动作，共19500张微多普勒图像的数据集上，采用“自监督预训练+下游分类器”的两阶段评估表明：MuPhyCoNet在10%标注率下的分类准确率为94.32%，较MoCo v2(72.19%)提升了22.13个百分点；且在本实验设定的各个加性噪声级别中均表现出较好的鲁棒性(以相对下降百分比计)，在SNR=12.5 dB的加性高斯白噪声扰动下仅下降5.49%，优于最佳非PI方法SimCLR v2(下降9.25%)。此外，针对部署阶段，物理预测分支可在推理时完全移除，仅保留骨干网络与轻量分类器，从而避免额外部署开销。未来工作将聚焦于(1)扩展至多目标与更复杂传播环境与更多路径组合的建模与验证；(2)引入自适应或在线标定以缓解系统参数偏差；(3)分析SimCLR在噪声下性能退化的根本原因与物理约束引入时的权衡，并据此

提出有针对性的改进方案(例如基于梯度流调整、负样本增强或混合架构的物理引导策略)。

**利益冲突** 所有作者均声明不存在利益冲突

**Conflict of Interests** The authors declare that there is no conflict of interests

## 参考文献

- [1] 孔令讲, 郭世盛, 陈家辉, 等. 多径利用雷达目标探测技术综述与展望[J]. 雷达学报(中英文), 2024, 13(1): 23–45. doi: [10.12000/JR23134](https://doi.org/10.12000/JR23134).
- [2] 蔡响, 韦顺军, 文彦博, 等. 基于非视距雷达三维成像的隐藏目标精确重构方法[J]. 雷达学报(中英文), 2024, 13(4): 791–806. doi: [10.12000/JR24060](https://doi.org/10.12000/JR24060).
- [3] 金添, 宋勇平, 崔国龙, 等. 低频电磁波建筑物内部结构透视技术研究进展[J]. 雷达学报, 2021, 10(3): 342–359. doi: [10.12000/JR20119](https://doi.org/10.12000/JR20119).
- [4] WU Peilun, CHEN Jiahui, GUO Shisheng, et al. NLOS positioning for building layout and target based on association and hypothesis method[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5101913. doi: [10.1109/TGRS.2023.3250831](https://doi.org/10.1109/TGRS.2023.3250831).
- [5] AHMED S and CHO S H. Machine learning for healthcare radars: Recent progresses in human vital sign measurement and activity recognition[J]. *IEEE Communications Surveys & Tutorials*, 2024, 26(1): 461–495. doi: [10.1109/COMST.2023.3334269](https://doi.org/10.1109/COMST.2023.3334269).
- [6] RAEIS H, KAZEMI M, and SHIRMOHAMMADI S. Human activity recognition with device-free sensors for well-being assessment in smart homes[J]. *IEEE Instrumentation & Measurement Magazine*, 2021, 24(6): 46–57. doi: [10.1109/MIM.2021.9513637](https://doi.org/10.1109/MIM.2021.9513637).
- [7] TANG Longzhen, GUO Shisheng, JIA Chao, et al. Human activity recognition based on multipath fusion in non-line-of-sight corner[J]. *IEEE Internet of Things Journal*, 2025, 12(23): 51467–51482. doi: [10.1109/JIOT.2025.3613792](https://doi.org/10.1109/JIOT.2025.3613792).
- [8] GUENDEL R G, KRUSE N C, FIORANELLI F, et al.

- Multipath exploitation for human activity recognition using a radar network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5103013. doi: [10.1109/TGRS.2024.3363631](https://doi.org/10.1109/TGRS.2024.3363631).
- [9] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4): 395–411. doi: [10.12000/JR18040](https://doi.org/10.12000/JR18040).  
WANG Jun, ZHENG Tong, LEI Peng, *et al.* Study on deep learning in radar[J]. *Journal of Radars*, 2018, 7(4): 395–411. doi: [10.12000/JR18040](https://doi.org/10.12000/JR18040).
- [10] ZHENG Zhijie, ZHANG Diankun, LIANG Xiao, *et al.* RadarFormer: End-to-end human perception with through-wall radar and transformers[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(12): 18285–18299. doi: [10.1109/TNNLS.2023.3314031](https://doi.org/10.1109/TNNLS.2023.3314031).
- [11] ZHANG Rui, GENG Ruixu, LI Yadong, *et al.* RFMamba: Frequency-aware state space model for RF-based human-centric perception[C]. The 13th International Conference on Learning Representations, Singapore, Singapore, 2025: 1–17.
- [12] HE Jianghaomiao, TERASHIMA S, YAMADA H, *et al.* Diffraction signal-based human recognition in non-line-of-sight (NLOS) situation for millimeter wave radar[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 4370–4380. doi: [10.1109/JSTARS.2021.3073678](https://doi.org/10.1109/JSTARS.2021.3073678).
- [13] SCHEINER N, KRAUS F, WEI Fangyin, *et al.* Seeing around street corners: Non-line-of-sight detection and tracking in-the-wild using doppler radar[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2020: 2065–2074. doi: [10.1109/CVPR42600.2020.00214](https://doi.org/10.1109/CVPR42600.2020.00214).
- [14] WAQAR S, MUAZ M, and PÄTZOLD M. Direction-independent human activity recognition using a distributed MIMO radar system and deep learning[J]. *IEEE Sensors Journal*, 2023, 23(20): 24916–24929. doi: [10.1109/JSEN.2023.3310620](https://doi.org/10.1109/JSEN.2023.3310620).
- [15] SALEH A A M and VALENZUELA R. A statistical model for indoor multipath propagation[J]. *IEEE Journal on Selected Areas in Communications*, 1987, 5(2): 128–137. doi: [10.1109/JSAC.1987.1146527](https://doi.org/10.1109/JSAC.1987.1146527).
- [16] 张锐, 龚汉钦, 宋瑞源, 等. 基于4D成像雷达的隔墙人体姿态重建与行为识别研究[J]. 雷达学报(中英文), 2025, 14(1): 44–61. doi: [10.12000/JR24132](https://doi.org/10.12000/JR24132).  
ZHANG Rui, GONG Hanqin, SONG Ruiyuan, *et al.* Through-wall human pose reconstruction and action recognition using four-dimensional imaging radar[J]. *Journal of Radars*, 2025, 14(1): 44–61. doi: [10.12000/JR24132](https://doi.org/10.12000/JR24132).
- [17] GE Yun, WANG Yiyu, LI Gen, *et al.* Multipath feature expansion for detection of human behaviors in NLOS region using mmWave radar[J]. *IEEE Transactions on Radar Systems*, 2025, 3: 864–874. doi: [10.1109/TRS.2025.3574571](https://doi.org/10.1109/TRS.2025.3574571).
- [18] DING Congzhang, GUO Shisheng, CUI Guolong, *et al.* A non-line-of-sight human activity recognition method based on radar multispectrogram[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2025, 61(5): 13647–13661. doi: [10.1109/TAES.2025.3579771](https://doi.org/10.1109/TAES.2025.3579771).
- [19] 陈彦, 张锐, 李亚东, 等. 基于无线信号的人体姿态估计综述[J]. 雷达学报(中英文), 2025, 14(1): 229–247. doi: [10.12000/JR24189](https://doi.org/10.12000/JR24189).  
CHEN Yan, ZHANG Rui, LI Yadong, *et al.* An overview of human pose estimation based on wireless signals[J]. *Journal of Radars*, 2025, 14(1): 229–247. doi: [10.12000/JR24189](https://doi.org/10.12000/JR24189).
- [20] LI Yadong, ZHANG Dongheng, CHEN Jinbo, *et al.* Towards domain-independent and real-time gesture recognition using mmWave signal[J]. *IEEE Transactions on Mobile Computing*, 2023, 22(12): 7355–7369. doi: [10.1109/TMC.2022.3207570](https://doi.org/10.1109/TMC.2022.3207570).
- [21] CHAN-TO-HING H and VEERAVALLI B. FUS-MAE: A cross-attention-based data fusion approach for masked autoencoders in remote sensing[C]. IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece, 2024: 6953–6958. doi: [10.1109/IGARSS53475.2024.10642424](https://doi.org/10.1109/IGARSS53475.2024.10642424).
- [22] FULLER A, MILLARD K, and GREEN J R. CROMA: Remote sensing representations with contrastive radar-optical masked autoencoders[C]. The 37th International Conference on Advances in Neural Information Processing Systems, New Orleans, USA, 2023: 241, 36: 5506–5538. doi: [10.52202/075280-0241](https://doi.org/10.52202/075280-0241).
- [23] XIE Yichen, CHEN Hongge, MEYER G P, *et al.* Cohere3D: Exploiting temporal coherence for unsupervised representation learning of vision-based autonomous driving[C]. IEEE International Conference on Robotics and Automation, Atlanta, USA, 2025: 10095–10102. doi: [10.1109/ICRA55743.2025.11127749](https://doi.org/10.1109/ICRA55743.2025.11127749).
- [24] SHAH K, SHAH A, LAU C P, *et al.* Multi-view action recognition using contrastive learning[C]. IEEE/CVF Winter Conference on Applications of Computer Vision, Waikoloa, USA, 2023: 3370–3380. doi: [10.1109/WACV56688.2023.00338](https://doi.org/10.1109/WACV56688.2023.00338).
- [25] KARNIADAKIS G E, KEVREKIDIS I G, LU Lu, *et al.* Physics-informed machine learning[J]. *Nature Reviews Physics*, 2021, 3(6): 422–440. doi: [10.1038/s42254-021-00314-5](https://doi.org/10.1038/s42254-021-00314-5).
- [26] RAISSI M, PERDIKARIS P, and KARNIADAKIS G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of Computational Physics*, 2019, 378: 686–707. doi: [10.1016/j.jcp.2018.10.045](https://doi.org/10.1016/j.jcp.2018.10.045).
- [27] ZHANG Tao, QIAO Xingshuai, LI Xiuping, *et al.* Radar feature analysis of human activity recognition under

- multiview scenes[J]. *IEEE Sensors Journal*, 2024, 24(14): 21997–22010. doi: [10.1109/JSEN.2023.3325619](https://doi.org/10.1109/JSEN.2023.3325619).
- [28] ZHU Haoran, HE Haoze, CHOROMANSKA A, *et al.* Multi-view radar autoencoder for self-supervised automotive radar representation learning[C]. IEEE Intelligent Vehicles Symposium, Jeju Island, Korea, Republic of, 2024: 1601–1608. doi: [10.1109/IV55156.2024.10588463](https://doi.org/10.1109/IV55156.2024.10588463).
- [29] HE Kaiming, FAN Haoqi, WU Yuxin, *et al.* Momentum contrast for unsupervised visual representation learning[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2020: 9726–9735. doi: [10.1109/CVPR42600.2020.00975](https://doi.org/10.1109/CVPR42600.2020.00975).
- [30] CHEN Xinlei, FAN Haoqi, GIRSHICK R, *et al.* Improved baselines with momentum contrastive learning[EB/OL]. arXiv: 2003.04297, 2020. doi: [10.48550/arXiv.2003.04297](https://doi.org/10.48550/arXiv.2003.04297).
- [31] HE Yonghua, WANG Jiangyu, LI Yonggang, *et al.* Research on radar clutter suppression methods[C]. IEEE Information Technology and Mechatronics Engineering Conference, Chongqing, China, 2023: 611–615. doi: [10.1109/ITOEC57671.2023.10291513](https://doi.org/10.1109/ITOEC57671.2023.10291513).
- [32] DOGARU T, NGUYEN L, and LE C. Computer models of the human body signature for sensing through the wall radar applications[R]. ARL-TR-4290, 2007.
- [33] PARK J K, PARK J H, KANG D K, *et al.* MPSK-MIMO FMCW radar-based indoor multipath recognition[J]. *IEEE Sensors Journal*, 2024, 24(17): 27824–27835. doi: [10.1109/JSEN.2024.3430082](https://doi.org/10.1109/JSEN.2024.3430082).
- [34] HAO Zhanjun, YAN Hao, DANG Xiaochao, *et al.* Millimeter-wave radar localization using indoor multipath effect[J]. *Sensors*, 2022, 22(15): 5671. doi: [10.3390/s22155671](https://doi.org/10.3390/s22155671).
- [35] PARK J K, PARK J H, and KIM K T. Multipath signal mitigation for indoor localization based on MIMO FMCW radar system[J]. *IEEE Internet of Things Journal*, 2024, 11(2): 2618–2629. doi: [10.1109/JIOT.2023.3292349](https://doi.org/10.1109/JIOT.2023.3292349).
- [36] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [37] WEN Yanbo, WEI Shunjun, CAI Xiang, *et al.* CMTI: Non-line-of-sight radar imaging for non-cooperative corner motion target[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(1): 179–190. doi: [10.1109/TVT.2024.3398218](https://doi.org/10.1109/TVT.2024.3398218).
- [38] LOSHCHILOV I and HUTTER F. SGDR: Stochastic gradient descent with warm restarts[C]. The 5th International Conference on Learning Representations, Toulon, France, 2017: 1–16.
- [39] GRILL J B, STRUB F, ALTCHÉ F, *et al.* Bootstrap your own latent a new approach to self-supervised learning[C]. The 34th International Conference on Neural Information Processing Systems, Vancouver, Canada, 2020: 1786.
- [40] CHEN Ting, KORNBLITH S, NOROUZI M, *et al.* A simple framework for contrastive learning of visual representations[C]. The 37th International Conference on Machine Learning, Vienna, Austria, 2020: 1597–1607.
- [41] VAN DEN OORD A, LI Yazhe, and VINYALS O. Representation learning with contrastive predictive coding[EB/OL]. arXiv: 1807.03748, 2018. doi: [10.48550/arXiv.1807.03748](https://doi.org/10.48550/arXiv.1807.03748).
- [42] MADRY A, MAKELOV A, SCHMIDT L, *et al.* Towards deep learning models resistant to adversarial attacks[C]. The 6th International Conference on Learning Representations, Vancouver, Canada, 2018: 1–23.

### 作者简介

钟晓玲，教授，主要研究方向为信号与信息处理、电磁感知与智能计算。

周俊霖，硕士生，主要研究方向为多径利用、雷达人体行为识别。

贾勇，教授，主要研究方向为雷达探测技术、人工智能应用。

祝庆曦，硕士生，主要研究方向为信号与信息处理。

姚光乐，副教授，主要研究方向为智能信号处理。

易诗，教授，主要研究方向为深度学习图像处理。

(责任编辑：于青)