

DOI:10.19651/j.cnki.emt.2519767

基于改进 MMoE 的联合活动识别与室内定位算法^{*}

康晓非 郭含玉 井溢洋

(西安科技大学通信与信息工程学院 西安 710600)

摘要: 随着多任务学习在非接触式 WiFi 感知中的广泛应用,如何同时提升联合活动识别与室内定位任务的准确率并保持任务间的平衡成为关键挑战。为此,本文提出了一种改进 MMoE 方法来实现联合活动识别与室内定位任务。该方法设计统一共享特征提取层用于提升输入特征的表达能;通过融合 XceptionTime 与 ResNet 构建多样化专家,前者适应于提取高频动态特征以提升活动识别准确率,后者则适合建模低频静态特征以提升定位精度;并引入双门控机制与正则化约束,在提升整体性能的同时有效平衡了两个任务的差异性。实验结果表明,所提方法在活动识别与室内定位两项任务上均优于现有代表性模型,展现出更高的准确性与稳定性。

关键词: WiFi 感知;信道状态信息;联合活动识别和室内定位;多门混合专家(MMoE)

中图分类号: TN92 **文献标识码:** A **国家标准学科分类代码:** 510.5015

Joint activity recognition and indoor localization algorithm based on improved MMoE

Kang Xiaofei Guo Hanyu Jing Yiyang

(School of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710600, China)

Abstract: With the wide application of multi-task learning in non-contact WiFi perception, how to simultaneously improve the accuracy of joint activity recognition and indoor positioning tasks and maintain a balance among tasks has become a key challenge. To this end, this paper proposes an improved MMoE method to achieve joint activity recognition and indoor localization tasks. This method designs a unified and shared feature extraction layer to enhance the expressive ability of the input features. By integrating XceptionTime and ResNet, a variety of experts are constructed. The former is suitable for extracting high-frequency dynamic features to improve the accuracy of activity recognition, while the latter is suitable for modeling low-frequency static features to enhance localization accuracy. It also introduces a dual-gate mechanism and regularization constraints, effectively balancing the differences between the two tasks while enhancing the overall performance. The experimental results show that the proposed method outperforms the existing representative models in both activity recognition and indoor localization tasks, demonstrating higher accuracy and stability.

Keywords: WiFi sensing; channel state information; joint activity recognition and indoor localization; multi-gate mixture-of-experts(MMoE)

0 引言

随着物联网(internet of things, IoT)技术的快速发展,如何利用现有基础设施实现对人类活动与位置的感知,成为智能家居^[1]、医疗保健^[2]、安防系统等众多场景中的研究热点。活动识别(activity recognition, AR)^[3-4]和室内定位(indoor localization, IL)^[5-6]作为人机交互系统的两大核心功能,在支持健康监控、异常检测、行为建模等方面具有重

要价值。传统方法主要依赖摄像头^[7]或可穿戴传感器^[8]。然而,视觉系统在非视距(non line of sight, NLoS)环境下性能严重受限,且容易引发隐私泄露问题;而可穿戴设备需要用户随身携带,会给用户带来不便。

近年来,基于无线射频(radio frequency, RF)^[9]信号的非接触式感知技术逐渐成为替代方案,其中, WiFi 感知技术因其部署广泛、低成本、穿透性强和保护隐私等优势而备受关注。特别是通过信道状态信息(channel state information,

收稿日期:2025-09-02

^{*} 基金项目:国家自然科学基金(62471384)项目资助

CSI)^[10]获取的细粒度数据,不仅能反映无线环境的变化,还能捕捉由人体活动引起的反射、散射和衰落特征,为非接触式人体感知提供了重要支撑。

一些研究成果已验证 WiFi 感知在人体活动识别、室内定位、手势识别^[11]和入侵检测^[12]等任务中的有效性。文献[13]提出结合残差网络双向长短期记忆网络(ResNet-BiLSTM)的活动识别方法,利用 ResNet 提取时空特征并通过 BiLSTM 建模序列依赖,在多个公共数据集上实现高识别率。而文献[14]提出了将 GRU 与 Inception 模块及注意力机制相结合的 GRU-INC 模型,有效提取多尺度时序特征并突出关键特征权重,在活动识别任务中进一步提升了模型性能。在室内定位领域,文献[15]提出了 MobLoc 方法,通过结合 MUSIC 算法提取角度信息,有效增强了 CSI 指纹的区分性,提高了系统在动态环境中的定位鲁棒性。文献[16]提出了一种基于图时序卷积网络(GTCN)的 WiFi 定位方法,利用 CSI 指纹构建位置图并同时建模空间与时间相关性,显著提升了定位精度。然而,这些研究多集中于单一任务建模,忽略了活动与位置之间的交互关联性。事实上,同一活动在不同空间语境下的意义可能完全不同,例如在智能家居环境中,“抬手”动作在客厅电视机前可能意味着增加音量,而在卧室空调前则可能表示提高温度。因此,联合活动识别与室内定位(joint activity identification and indoor localization, JARIL)具有重要的研究意义,不仅能提供更高层次的语义理解,也更符合智能系统中的实际需求。近年来部分研究开始探索活动识别与室内定位的多任务学习方法,文献[17]首次提出以 WiFi CSI 指纹同时完成活动与位置的识别任务,通过共享特征提取网络,分别预测用户的活动类别与位置索引,有效提升了两个任务的整体性能。文献[18]引入深度残差收缩网络,通过残差特征强化与噪声抑制机制,提升了模型对微弱动作特征的辨识

能力,在室内复杂场景中展现出更好的稳定性。文献[19]引入多标签学习与正则化约束机制,强调任务之间的结构约束与信息共享,在保持精度的同时提升了模型的泛化性。文献[20]针对双任务的异构特征需求,设计非对称注意力网络(WiADN),以差异化关注机制实现任务特定特征提取,在保证共享信息有效传递的同时增强任务独立建模能力。

尽管现有方法在联合任务建模上取得了创新性成果,但在解决梯度竞争和优化任务失衡方面仍面临挑战,此外,进一步提高多任务的预测准确率和模型的泛化能力也有待探索。基于此,本文提出了一种基于传统多门混合专家(multi-gate mixture-of-experts, MMoE)^[21]的改进 MMoE 方法,与传统 MMoE 相比,本研究的创新主要体现在:引入共享特征提取层和异构专家网络,共享特征提取层的设计有效提升了输入特征的表达能力,为多任务建模奠定坚实的特征基础。通过融合 XceptionTime^[22]与 ResNet 构建多样化专家,前者由于采用深度可分离卷积与多尺度感受野机制,擅长捕捉局部活动变化,因此更适合处理活动识别任务;后者在捕捉稳定、低频变化的特征方面具有较强表现,适用于提取定位任务中具有空间连续性和局部稳定性的特征。此外,通过分别为各任务设计的门控网络,实现对专家输出的动态选择与融合。同时在损失函数中引入 L2 正则化,进一步增强模型的泛化能力与鲁棒性。本文提出的改进 MMoE 在保持多任务共享优势的同时,突破了传统 MMoE 在特征共享与专家多样性方面的局限,显著提升了模型在活动识别与室内定位任务中的整体性能与稳定性。

1 改进 MMoE 的算法原理

本文提出的改进 MMoE 的算法原理如图 1 所示,主要包括 CSI 数据采集模块、离线训练阶段与在线测试阶段这 3 部分。

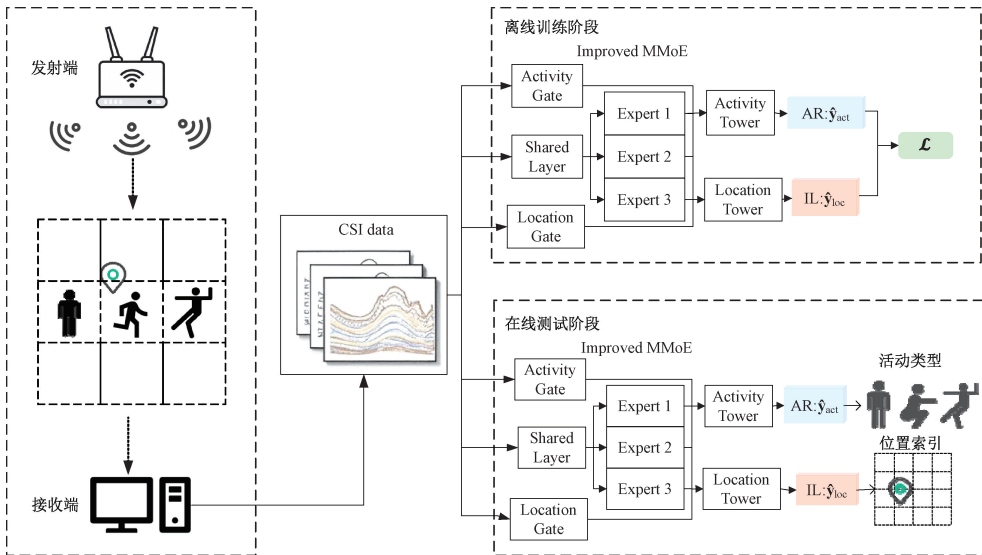


图 1 提出的改进 MMoE 的算法原理

Fig. 1 The algorithm principle of the proposed improved MMoE

在 CSI 数据采集模块中, WiFi 发射端(如无线路由器)持续发射无线信号,当人体在信号覆盖范围内进行不同活动时,人体动作会对无线信道状态产生影响,从而引起接收信号的衰减和多径变化。这些变化通过接收端实时记录并形成对应的 CSI 样本。CSI 数据作为输入,进一步用于特征提取与模型训练。

在离线训练阶段, CSI 数据被输入至改进 MMoE 架构中,模型中包含多个专家网络,分别针对两个任务提取共享与特定特征。网络输出包括活动识别结果 \hat{y}_{act} 和位置识别结果 \hat{y}_{loc} , 训练过程中采用联合损失函数 \mathcal{L} 进行优化,并引入 L2 正则化以提升模型泛化能力。

在线测试阶段,利用训练好的模型对 CSI 数据进行测试,同时输出当前的人体活动类型和对应的室内位置索引,从而实现对人类活动和位置的联合感知。

2 改进 MMoE 的 JARIL 模型

2.1 问题描述

在基于 CSI 指纹的无线感知技术中,活动识别和室内定位通常被建模为两个独立的分类问题。而 JARIL 作为这两项任务的联合学习问题,其本质是一个多标签分类挑战。其中,输入为 CSI 幅值,可以表示为 $\mathbf{x} \in \mathbb{R}^{C_{in} \times L}$, 其中

C_{in} 表示正交频分复用子载波的数量, L 表示采样点数。每个 CSI 样本都同时对对应经过 one-hot 编码的活动标签和位置标签,活动标签可以表示为 $\mathbf{y}_{act} \in \mathbb{R}^{N \times 1}$, 其中 N 表示活动识别的类别数,位置标签可以表示为 $\mathbf{y}_{loc} \in \mathbb{R}^{M \times 1}$, M 表示室内定位的类别数。因此, JARIL 问题可表示为:

$$\hat{\mathbf{y}}_{act}, \hat{\mathbf{y}}_{loc} = \underset{\mathbf{y}_{act} \in \mathcal{Y}_{act}, \mathbf{y}_{loc} \in \mathcal{Y}_{loc}}{\operatorname{argmax}} f(\mathbf{y}_{act}, \mathbf{y}_{loc} | \mathbf{x}; \mathbf{W}) \quad (1)$$

式中: $f(\cdot)$ 是样本空间 \mathcal{X} 到联合标签空间 $\mathcal{Y}_{act} \cup \mathcal{Y}_{loc}$ 的多标签映射函数, \mathbf{W} 是神经网络可学习权重,它包括共享特征权重 \mathbf{W}_{shared} 、专家权重 \mathbf{W}_{exp} 、两个门控权重 \mathbf{W}_{gate}^{act} 和 \mathbf{W}_{gate}^{loc} 以及两个任务塔权重 \mathbf{W}_{act} 和 \mathbf{W}_{loc} , 即 $\mathbf{W} = \{\mathbf{W}_{shared}, \mathbf{W}_{exp}, \mathbf{W}_{gate}^{act}, \mathbf{W}_{gate}^{loc}, \mathbf{W}_{act}, \mathbf{W}_{loc}\}$ 。

2.2 模型总体架构

本文提出的改进 MMoE 的 JARIL 模型如图 2 所示。模型包含共享特征预处理层、专家网络、门控机制和任务塔 4 个模块。共享特征预处理层用于对原始 CSI 数据进行特征提取,以捕捉时间序列的局部模式和长期依赖性;专家网络包含 XceptionTime 和 ResNet 两种专家结构,以学习不同尺度的 CSI 信号特征;门控机制为不同任务动态分配专家权重,实现任务特定的专家选择;任务特定塔分别用于活动识别和室内定位,以生成最终的预测结果。下面将详细描述这 4 个模块的具体设计与实现细节。

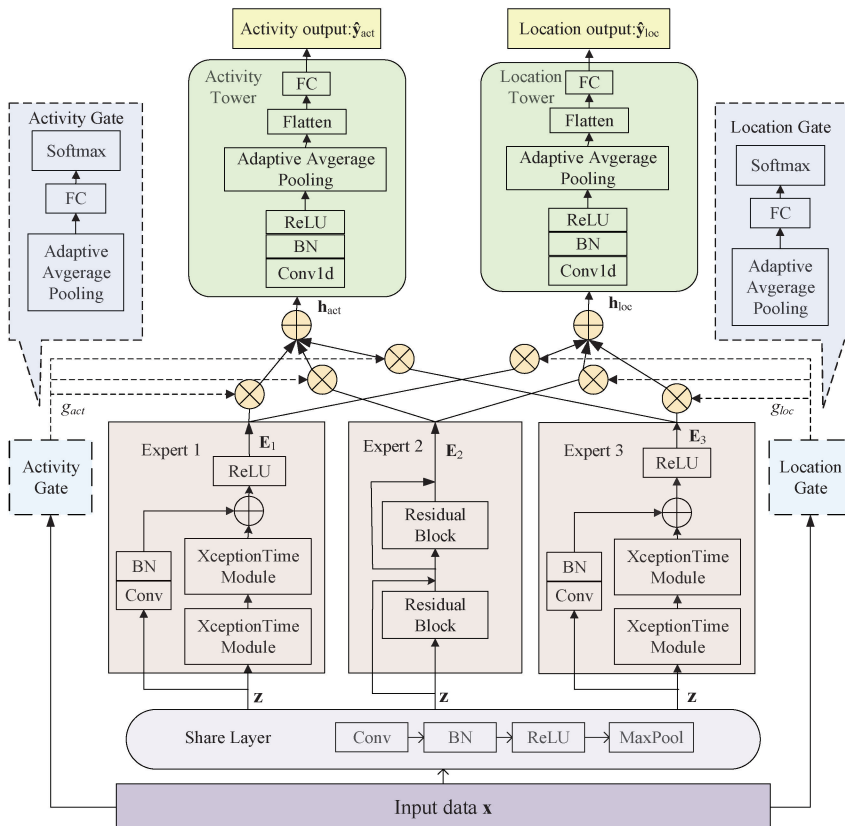


图 2 提出的改进 MMoE 的 JARIL 模型

Fig. 2 The proposed improved JARIL model of MMoE

2.3 共享特征预处理层

模型的输入 x 为 CSI 时间序列, CSI 时间序列首先通过一个一维卷积层(Conv1D)提取底层特征,卷积核大小设为 7,并使用批归一化(BatchNorm)和 ReLU 激活函数,以增强特征的表达能力和加速训练收敛,随后,采用最大池化层(MaxPool)进行降采样,以减少计算量并增强模型的鲁棒性,由此得到一个共享的特征表示 z :

$$z = f_{MaxPool}(f_{ReLU}(f_{BN}(f_{conv}(x, W_{shared})))) \quad (2)$$

式中: $f_{MaxPool}$ 表示最大池化, $f_{ReLU}(\cdot)$ 为激活函数, $f_{conv}(\cdot)$ 和 $f_{BN}(\cdot)$ 分别表示批归一化处理 and 卷积处理, W_{shared} 表示共享特征权重。

通过这一结构,模型不仅能够提取与任务无关的稳定特征,还为后续专家网络和门控机制的分任务建模提供了坚实的特征基础。

2.4 专家网络

本研究设计了两种专家网络,分别基于 XceptionTime 和 ResNet 结构。设置的专家数量为 3 个,其中专家 1 和专家 3 均采用 XceptionTime 结构,专家 2 采用 ResNet 结构。这种设计的目的:一方面,结合两种不同的深度特征提取方法,以充分挖掘 CSI 信号的时序特征和空间相关性;另一方面,考虑到两个任务的不平衡性,更多的专家用于较难的活动识别任务。每个专家接受相同的输入 z , 专家的输出为 E_k :

$$E_k = f_{exp}^k(z, W_{exp}), k = 1, 2, 3 \quad (3)$$

式中: $f_{exp}^k(\cdot)$ 表示专家网络, k 表示专家编号,当 $k=1$ 或 $k=3$ 时,采用 XceptionTime 专家;当 $k=2$ 时,采用 ResNet 专家; W_{exp} 表示专家权重。

XceptionTime 专家由两个级联的 XceptionTime 模块组成,两个模块之间有一个卷积层和批归一化层组成残差连接。XceptionTime 模块的结构如图 3 所示,它是一种基于深度可分离卷积(depthwise separable convolution)的高效时序建模结构,该模块受 IceptionTime^[23] 的启发,通过分离时域与通道方向的卷积操作,能够以更低的计算代价提取高维、时序敏感的特征。XceptionTime 模块包括两条并行路径:第 1 层路径有一个卷积层,后跟 3 个具有不同卷积核大小的深度可分离卷积,通过合并深度可分离卷积, XceptionTime 模块的参数和计算需求都大大降低。第 2 路径有一个最大池化层,后跟一个卷积层。最后将生成的特征图连接起来以构建输出特征。

XceptionTime 专家通过多尺度深度可分离卷积和残差连接的方式构建,能够有效增强模型对局部活动变化、细粒度动态的捕捉能力,非常适合建模活动识别中快速频繁的状态变化。

ResNet 专家网络的网络结构如图 4 所示。它由两个残差块(residual block, RB)组成,每个残差块由两个卷积层(Conv1D)和一个残差连接构成。

ResNet 凭借其深层残差连接结构,具有较强的稳定性

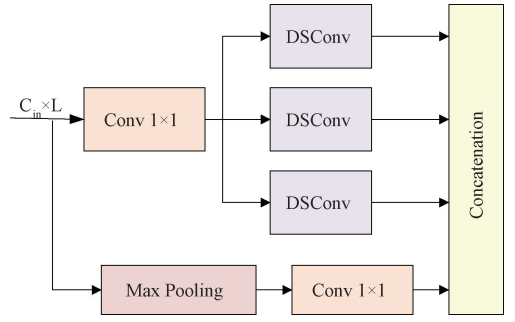


图 3 XceptionTime 模块
Fig. 3 XceptionTime module




图 4 ResNet 专家模块
Fig. 4 ResNet expert module

与泛化能力。其优势在于保持信息流动与梯度稳定,适用于捕捉相对平稳、结构化的时序模式,尤其在空间位置相关模式中表现良好。因此,本研究将其作为另一个专家网络,用于提取定位任务中具有空间连续性和局部稳定性的特征。

2.5 门控机制

改进 MMoE 模型采用任务特定门控(task-specific gating)机制,其作用是为每个任务动态分配专家权重。门控网络采用全局平均池化(Adaptive AvgPool1d)进行特征降维,经过全连接层计算各专家的权重;通过 Softmax 归一化,确保不同专家的权重总和为 1。活动识别和室内定位两个任务分别对应一个门控网络:

$$g_{act} = f_{Softmax}[f_{GAP}(x, W_{gate}^{act})] \quad (4)$$

$$g_{loc} = f_{Softmax}[f_{GAP}(x, W_{gate}^{loc})] \quad (5)$$

式中: $f_{Softmax}(\cdot)$ 是 Softmax 激活函数, $f_{GAP}(\cdot)$ 是全局平均池化。门控网络的输出向量,可进一步分别表示为 $g_{act} = [g_{act}^1 \ g_{act}^2 \ g_{act}^3]$ 和 $g_{loc} = [g_{loc}^1 \ g_{loc}^2 \ g_{loc}^3]$ 。最终,所有专家加权求和得到每个任务的特征表示:

$$h_{act} = \sum_{k=1}^K g_{act}^k \cdot E_k \quad (6)$$

$$\mathbf{h}_{loc} = \sum_{k=1}^K \mathbf{g}_{loc}^k \cdot \mathbf{E}_k \quad (7)$$

式中: K 表示专家的数量, \mathbf{E}_k 表示专家网络。

这样,门控网络确保了每个任务能够选择最具判别力的专家特征,而不会受到无关任务特征的干扰,从而实现联合活动识别与室内定位的最优特征融合。

2.6 任务塔

对于活动识别和室内定位两个任务,模型最后采用两个独立的任务塔,这两个任务塔的结构大致相同,首先通过卷积层提取特征,再通过批量归一化和激活函数增强网络的训练稳定性和非线性表达能力,然后采用全局平均池化进行降维,最后通过全连接层进行分类。最终输出可以表示为:

$$\hat{\mathbf{y}}_{act} = f_{FC}(f_{GAP}(f_{ReLU}(f_{Conv}(\mathbf{h}_{act}, \mathbf{W}_{act})))) \quad (8)$$

$$\hat{\mathbf{y}}_{loc} = f_{FC}(f_{GAP}(f_{ReLU}(f_{Conv}(\mathbf{h}_{loc}, \mathbf{W}_{loc})))) \quad (9)$$

式中: $\hat{\mathbf{y}}_{act}$ 表示活动识别的预测结果, $\hat{\mathbf{y}}_{loc}$ 表示室内定位的预测结果, $f_{FC}(\cdot)$ 表示全连接层。

2.7 损失函数

为了进一步提升模型在复杂环境下的泛化能力,本文在联合多任务损失函数中引入了 L2 正则化项。该设计不仅关注任务本身的预测精度,同时有效抑制了模型参数的过拟合风险。损失函数定义如下:

$$\mathcal{L} = \lambda \mathcal{L}_{act}(\hat{\mathbf{y}}_{act}, \mathbf{y}_{act}) + (1-\lambda) \mathcal{L}_{loc}(\hat{\mathbf{y}}_{loc}, \mathbf{y}_{loc}) + \alpha \|\mathbf{W}\|_2^2 \quad (10)$$

式中: \mathcal{L}_{act} 和 \mathcal{L}_{loc} 分别表示活动识别与室内定位的交叉熵损失, $\|\mathbf{W}\|_2^2$ 是 L2 正则化, α 为 L2 正则化系数,用于防止模型过拟合。 λ 是用于平衡两个任务的超参数,取值范围为 $0 \leq \lambda \leq 1$ 。两个任务的交叉熵损失函数定义为:

$$\mathcal{L}_{act} = - \sum_{n=1}^N \mathbf{y}_{act}^n \log(\hat{\mathbf{y}}_{act}^n) \quad (11)$$

$$\mathcal{L}_{loc} = - \sum_{m=1}^M \mathbf{y}_{loc}^m \log(\hat{\mathbf{y}}_{loc}^m) \quad (12)$$

式中: N 表示活动识别的类别数, M 表示室内定位的类别数, \mathbf{y}_{act}^n 表示活动识别真实类别的 one-hot 编码, \mathbf{y}_{loc}^m 表示室内定位真实类别的 one-hot 编码, $\hat{\mathbf{y}}_{act}^n$ 表示模型对活动识别中 n 的预测概率, $\hat{\mathbf{y}}_{loc}^m$ 是模型对室内定位中类别 m 的预测概率。

3 实验结果及性能分析

3.1 实验设置

数据集:本文采用公开的 ARIL^[17] 数据集进行实验。每个 CSI 指纹包含 52 个子载波和 192 个样本。为确保公平比较,本文舍弃了 CSI 相位信息,仅保留幅度数据作为特征输入。数据集涵盖 6 种手部活动的标签,具体包括:手向上(up)、手向下(down)、手向左(left)、手向右(right)、手绕圈(circle)和手交叉(cross)。这些活动在 16 个不同位置执行,位置编号为 #0~#15。每个活动重复 15 次,原始

数据集包含 1 440 个样本。然而,46 个异常值被丢弃,使得最终样本的数量变为 1 394。每个样本的维度为 52×192 ,使用 1 394 个样本中的 80% 作为训练集,剩余的作为测试集。

模型的实现基于 PyTorch 框架,优化器采用 Adam,模型训练的主要参数如表 1 所示。

表 1 模型参数设置

Table 1 Model parameter settings	
参数	值
学习率	0.001
损失函数	Cross-Entropy Loss
训练批次大小 batch size	16
训练轮次 epochs	300
专家数量 K	3
活动类别数 N	6
位置类别数 M	16

3.2 实验结果与分析

为了全面评估本文所提出的改进 MMoE 方法的性能,在相同实验环境下将其与多种模型进行了对比测试。包括传统的机器学习方法 CNN、CNN-BiLSTM,早期用于活动识别和室内定位任务的 ResNet1D^[17]、ResNet1D+^[17] 和 DenseNet1D^[24],以及最新的 WiFi 感知方法 RML^[19] 和 WiADN^[20]。表 2 展示了各模型在活动识别与室内定位任务上的分类准确率,通过对比实验可以看出,本文提出的方法在活动识别与室内定位任务上均取得了优异的性能。具体而言,在活动识别任务上,本文方法相较于现有先进模型进一步提升了准确率,达到了 96.76%,在室内定位任务上也保持了与最优方法持平的 99.64% 准确率,验证了本方法的有效性和先进性。

表 2 不同方法的准确率对比

Table 2 Comparison of accuracy rates of different methods		
方法	AR 准确率/%	IL 准确率/%
CNN ^[19]	53.96	79.50
CNN-BiLSTM ^[19]	66.91	91.73
ResNet1D ^[17]	88.13	95.68
ResNet1D+ ^[17]	89.57	95.68
RML ^[19]	91.73	99.64
DenseNet1D ^[24]	95.31	99.48
WiADN ^[20]	96.40	98.76
Proposed	96.76	99.64

图 5 和 6 显示了活动识别和室内定位的损失函数的学习曲线。从图中可以看出,两个任务在前 50 个 epoch 左右,测试损失波动较大,而训练损失相对平稳但也在快速下降。这表明模型仍在调整权重参数。经过约 50 个

epoch 之后,两个任务的训练和测试损失都呈现下降趋势,并逐渐趋于稳定。这表明模型逐渐学习到了有效的特征表示。在 100 个 epoch 之后,训练损失和测试损失趋近于零,说明模型能够很好地拟合数据,并且未出现明显的过拟合现象。在室内定位任务中,测试损失稍微高于训练损失,但仍然维持在较低水平,表明模型的泛化性能较好。在活动识别任务中,测试损失的下降速度稍慢于训练损失,表明该任务可能比室内定位任务更具挑战性,但最终仍然达到了良好的收敛状态。




图 5 活动识别的损失函数学习曲线

Fig. 5 The learning curve of the loss function for activity recognition




图 6 室内定位的损失函数学习曲线

Fig. 6 The learning curve of the loss function for indoor localization

总体来看,所提出的模型能够稳定收敛,并且在 50~100 个 epoch 之间就基本完成了特征学习,最终的损失保持在较低水平,说明该模型在两个任务上的性能较为优越。

图 7 和 8 展示了模型在活动识别和室内定位任务上的训练和测试准确率随 epoch 的变化情况。从图中可以看出模型在大约 50 个 epoch 后趋于收敛,训练和测试准确率都趋于稳定。通过对比分析活动识别与室内定位任务的学习曲线,可以观察到室内定位任务展现出更快的收敛速度以及更优的性能表现,这表明模型在位置识别任务上具有

更强的特征提取能力。




图 7 活动识别的准确率学习曲线

Fig. 7 The accuracy learning curve of activity recognition




图 8 室内定位的准确率学习曲线

Fig. 8 The accuracy learning curve of indoor localization

该模型关于活动识别和室内定位的混淆矩阵分别如图 9 和 10 中所示,从图 9 可以观察到,该模型对类别 up、down、left、right 的预测准确率较高,均在 95% 以上,对类别 circle 和 cross 的预测准确率略低,这可能是由于部分活动之间存在着重叠特征。从图 10 可以观察到,模型对绝大多数位置的预测非常稳定和可靠,仅在预测位置 # 15 时存在轻微混淆,部分类别准确率较低主要是由于样本不平衡或特征相似导致模型难以区分。但从整体来看,两个任务的混淆矩阵结果均表现优异,说明所提出的改进 MMoE 方法具有出色的特征提取能力和多任务学习能力。

为了分析不同任务的损失函数权重对模型性能的影响,本实验通过调节两个任务损失函数的权重 $\lambda \in [0.1, 0.9]$,记录模型在活动识别和室内定位上的准确率,绘制如图 11 所示的对比曲线。从图中可以看出,模型对室内定位任务的鲁棒性较强,损失权重较小也能维持较高准确率。活动识别任务对权重更敏感,适当提高其损失权重能显著提升准确率。因此,本实验在损失权重分配上以活动识别为主导,设置 $\lambda = 0.8$,以兼顾两项任务的高准确率,特别是在不明显牺牲定位性能的前提下。




图9 活动识别混淆矩阵

Fig. 9 Confusion matrix for activity recognition




图10 室内定位混淆矩阵

Fig. 10 Confusion matrix for indoor localization

为验证所提模型在不同数据集上的泛化性能与鲁棒性,本文在ARIL与Widar3.0^[4]两个典型WiFi CSI数据集上分别进行了实验,结果如图12所示。从图12中可以看出,该模型在两个数据集上的实验结果均保持在较高水平,说明该模型在不同环境、设备与场景条件下依然具有良好的适应性与稳定性,验证了模型良好的鲁棒性。

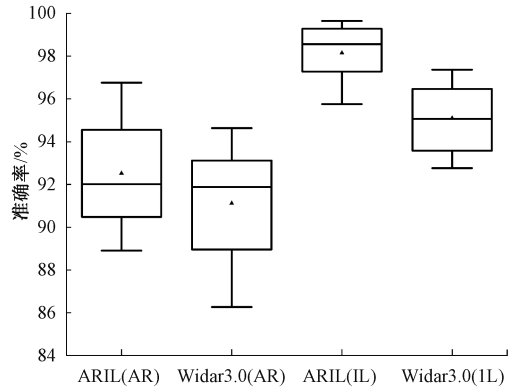


图12 模型在不同数据集上的表现

Fig. 12 The performance of the model on different datasets

4 结 论

本文提出了一种改进MMoE的JARIL方法,以同时实现人体活动识别与室内定位任务。该方法旨在解决JARIL中准确率受限与任务间的不平衡问题。具体而言,该方法通过构建统一共享特征提取层有效提升输入特征的代表能力,通过设计多个专家网络建模任务间的共享与差异,并引入双门控机制与正则化约束动态平衡专家分配与任务学习权重。仿真结果表明,所提出的方法在活动识别与室内定位两个任务上均优于现有主流方法,AR的准确率为96.76%,IL的准确率达到99.64%。在多个对比实验中,本模型在保持高准确率的同时,也展现了更强的收敛能力和泛化性能。

参考文献

[1] BOUCHABOU D, NGUYEN S M, LOHR C, et al. A survey of human activity recognition in smart homes based on IoT sensors algorithms: Taxonomies, challenges, and opportunities with deep learning[J]. Sensors, 2021, 21(18): 6037.

[2] YANG Y, WANG H, JIANG R, et al. A review of IoT-enabled mobile healthcare: Technologies, challenges, and future trends[J]. IEEE Internet of Things Journal, 2022, 9(12): 9478-9502.

[3] 孙巍伟,毛亦鹏,郑家春,等. 基于改进Transformer-BiLSTM的人体活动识别模型[J]. 电子测量技术, 2024, 47(17): 54-61.

SUN W W, MAO Y P, ZHENG J CH, et al. Human activity recognition model based on improved




图11 固定权重下准确率的变化

Fig. 11 The change in accuracy under fixed weights

- Transformer-BiLSTM [J]. *Electronic Measurement Technology*, 2024, 47(17): 54-61.
- [4] ZHANG Y, ZHENG Y, QIAN K, et al. Widar3.0: Zero-effort cross-domain gesture recognition with Wi-Fi [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(11): 8671-8688.
- [5] ZHANG B, SIFAOU H, LI G Y. CSI-fingerprinting indoor localization via attention-augmented residual convolutional neural network [J]. *IEEE Transactions on Wireless Communications*, 2023, 22(8): 5583-5597.
- [6] LIU M M, LIAO X W, GAO ZH ZH, et al. FT-Loc: A fine-grained temporal features-based fusion network for indoor localization [J]. *IEEE Internet of Things Journal*, 2023, 11(3): 4324-4334.
- [7] BELTRAN J, GUINDEL C, DE LA ESCALERA A, et al. Automatic extrinsic calibration method for lidar and camera sensor setups [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(10): 17677-17689.
- [8] KAI DAROVA A, GERALDI N R, WILSON R P, et al. Wearable sensors for monitoring marine environments and their inhabitants [J]. *Nature Biotechnology*, 2023, 41(9): 1208-1220.
- [9] WANG F, LYU Y ZH, ZHU M D, et al. Xrf55: A radio frequency dataset for human indoor action analysis [J]. *ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2024, 8(1): 1-34.
- [10] CHEN CH, ZHOU G, LIN Y F. Cross-domain WiFi sensing with channel state information: A survey [J]. *ACM Computing Surveys*, 2023, 55(11): 1-37.
- [11] 何育浪, 赵志彪, 李振, 等. 基于 DSC-SGRU 模型的 Wi-Fi 手势识别系统研究 [J]. *电子测量与仪器学报*, 2024, 38(10): 97-108.
- HE Y L, ZHAO ZH B, LI ZH, et al. Research on Wi-Fi gesture recognition system based on DSC-SGRU model [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(10): 97-108.
- [12] 赵宗扬, 康杰虎, 吴斌, 等. 基于 FRL-Net 的高鲁棒性多尺度小样本轨道入侵异物检测方法研究 [J]. *仪器仪表学报*, 2024, 45(1): 239-249.
- ZHAO Z Y, KANG J H, WU B, et al. Research on high robustness multi-scale small sample orbital intrusion foreign object detection method based on FRL-Net [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(1): 239-249.
- [13] LI Y, WANG L. Human activity recognition based on residual network and BiLSTM [J]. *Sensors*, 2022, 22(2): 635.
- [14] MIM T R, AMATULLAH M, AFREEN S, et al. GRU-INC: An inception-attention based approach using GRU for human activity recognition [J]. *Expert Systems with Applications*, 2023, 216: 119419.
- [15] MAZOKHA S, BAO F, SKLIVANITIS G, et al. MobLoc: CSI-based location fingerprinting with MUSIC [J]. *IEEE Journal of Indoor and Seamless Positioning and Navigation*, 2023, 1: 231-241.
- [16] LIU X, WU R, ZHANG H, et al. Graph temporal convolution network-based wifi indoor localization using fine-grained csi fingerprint [J]. *IEEE Sensors Journal*, 2025, 25(5): 9019-9033.
- [17] WANG F, FENG J F, ZHAO Y L, et al. Joint activity recognition and indoor localization with WiFi fingerprints [J]. *IEEE Access*, 2019, 7: 80058-80068.
- [18] 张力, 常俊, 武浩, 等. 深度残差收缩网络下的定位与行为联合识别 [J]. *计算机工程与应用*, 2022, 58(21): 205-212.
- ZHANG L, CHANG J, WU H, et al. Joint recognition of localization and behavior in deep residual contraction networks [J]. *Computer Engineering and Applications*, 2022, 58(21): 205-212.
- [19] WANG Y, ZHAO H, OHTSUKI T, et al. Regularized multi-Label learning empowered joint activity recognition and indoor localization with CSI fingerprints [J]. *IEEE Transactions on Wireless Communications*, 2024, 23(11): 16865-16874.
- [20] ZHOU J, LIAO X, GAO Z, et al. WiADN: Asymmetrical dual-task attention network for WiFi sensing [J]. *IEEE Internet of Things Journal*, 2024, 11(24): 39435-39447.
- [21] MA J Q, ZHAO ZH, YI X Y, et al. Modeling task relationships in multi-task learning with multi-gate mixture-of-experts [C]. *24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018.
- [22] RAHIMIAN E, ZABIHI S, ATASHZAR S F, et al. Xceptiontime: Independent time-window xceptiontime architecture for hand gesture classification [C]. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2020: 1304-1308.
- [23] ISMAIL FAWAZ H, LUCAS B, FORESTIER G, et al. Inceptiontime: Finding alexnet for time series classification [J]. *Data Mining and Knowledge Discovery*, 2020, 34(6): 1936-1962.
- [24] IRAWAN A, PUTRA A M, RAMADHAN H. A DenseNet model for joint activity recognition and indoor localization [C]. *2022 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)*. IEEE, 2022: 61-65.

作者简介

康晓非(通信作者), 副教授, 主要研究方向为宽带无线通信中的信道估计和信号检测技术、室内无线定位技术。

E-mail: kangxiaofei@xust.edu.cn

郭含玉, 硕士研究生, 主要研究方向为无线室内定位技术。

E-mail: 2258111479@qq.com

井溢洋, 硕士研究生, 主要研究方向为信号检测技术。

E-mail: 1968887251@qq.com