

# 基于可穿戴运动护膝和个性化联邦学习的健身动作识别方法

丁磊<sup>1</sup>, 李思维<sup>1</sup>, 黄瑞婷<sup>1</sup>, 余慧坤<sup>1</sup>, 余烈<sup>2</sup>

(1. 武汉纺织大学计算机与人工智能学院, 湖北 武汉 430200; 2. 武汉纺织大学电子与电气工程学院, 湖北 武汉 430200)

**摘要:** 针对基于可穿戴设备的健身动作识别方法收集标注的传感器数据可能造成隐私泄露风险, 以及传统中心化模型训练方法在新用户适应性方面存在局限的问题, 提出一种基于可穿戴运动护膝和个性化联邦学习(FL)的健身动作识别方法。该方法实现了健身动作类型识别和用户表现水平识别两项任务, 帮助用户了解自身健身表现, 提高锻炼效果。首先, 将每位用户视为独立的任务, 以联邦的方式元训练一个全局嵌入网络, 学习跨用户的共享表征, 此表征可以有效地泛化到任意用户; 然后, 通过一个适应化流程, 在全局嵌入网络的基础上对本地分类网络进行两阶段微调, 使每位用户获得个性化模型; 最后, 在来自真实世界的健身数据集上进行大量实验, 以验证该方法的性能表现。实验结果表明, 所提方法实现了 100% 的健身动作类型识别准确率和 95.94% 的用户表现水平识别准确率, 显著优于现有先进方法。所提系统能够保护用户隐私, 同时具备良好的新用户泛化能力。

**关键词:** 健身动作识别; 可穿戴运动护膝; 个性化联邦学习; 隐私保护; 全局嵌入网络

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0252004

## Fitness Action Recognition Method Based on Wearable Sports Knee Sleeve and Personalized Federated Learning

DING Lei<sup>1</sup>, LI Siwei<sup>1</sup>, HUANG Ruiting<sup>1</sup>, YU Huikun<sup>1</sup>, YU Lie<sup>2</sup>

(1. School of Computer Science and Artificial Intelligence, Wuhan Textile University, Wuhan 430200, Hubei, China;

2. School of Electronics and Electrical Engineering, Wuhan Textile University, Wuhan 430200, Hubei, China)

**【Abstract】** To address the privacy leakage risks associated with collecting and annotating sensor data for wearable device-based fitness action recognition as well as the limitations of traditional centralized model training in adapting to new users, this study proposes a fitness action recognition method based on a wearable sports knee sleeve and personalized Federated Learning (FL). The method accomplishes two tasks, namely fitness action type recognition and user performance level recognition, to help users understand their fitness performance and improve exercise effectiveness. First, each user is treated as an independent task, and a global embedding network is meta-trained in a federated manner to learn user-agnostic shared representations that can be effectively generalized for any user. Subsequently, through an adaptation procedure, the local classification network is fine-tuned in two stages on top of the global embedding network, enabling each user to obtain a personalized model. Finally, extensive experiments are conducted on a real-world fitness dataset to validate the performance of the proposed method. The experimental results demonstrate that the proposed method achieves 100% accuracy in fitness action type recognition and 95.94% accuracy in user performance level recognition, significantly outperforming existing state-of-the-art methods. The proposed system can protect user privacy while exhibiting a strong generalization ability for new users.

**【Key words】** fitness action recognition; wearable sports knee sleeve; personalized Federated Learning (FL); privacy protection; global embedding network

## 0 引言

随着人们健康意识的增强, 参与健身运动的人日益增加。相较传统的去健身房锻炼, 居家健身因其灵活性和经济性的特点, 受到许多健身爱好者的青睐<sup>[1]</sup>。然而, 由于缺乏专业人士的指导, 锻炼者可能无法达到理想的锻炼效果甚至造成身体损伤<sup>[2]</sup>。因此, 为居家锻炼者提供健身监测, 帮助提高个人运

动表现十分重要<sup>[3]</sup>。

近年来, 随着可穿戴技术的快速发展, 健身追踪器、智能手表、心率监测仪等设备在健身监测领域得到了广泛应用。2023 年, 全球可穿戴设备(主要包括健身追踪器和智能手表)出货量已超过 5 亿台, 预计到 2028 年, 这一数字将至少增长 25%<sup>[4]</sup>。尽管可穿戴设备推动了健身监测技术的发展, 但其带来的数据隐私问题需要关注和解决<sup>[5]</sup>。

**基金项目:** 湖北省自然科学基金面上项目(2022CFB563)。

**作者简介:** 丁磊, 男, 副教授、博士, 主研方向为柔性传感、步态分析; 李思维, 硕士; 黄瑞婷、余慧坤, 本科生; 余烈(通信作者), 副教授、博士。

收稿日期: 2025-01-03

修回日期: 2025-03-13

E-mail: lyu@wtu.edu.cn

现有的健身动作识别方法主要分为 3 类,即基于摄像头的方法、基于无线设备的方法和基于穿戴设备的方法。

基于摄像头的方法采用相机或手机摄像头进行健身监测。文献[6]利用商用 RGB 相机跟踪健身动作,实现重复动作计数。文献[7]利用手机相机对瑜伽运动进行监测和识别,并帮助用户纠正错误姿势。然而,基于摄像头的方法容易受到光照条件和遮挡的影响<sup>[8]</sup>,且在家庭环境中部署摄像头存在隐私泄露风险。

基于无线设备的方法使用毫米波、Wi-Fi 等无线信号,提供非接触式的锻炼监测。文献[9]使用单个毫米波设备对多种全身动作进行识别,并支持多用户的健身监测。文献[10-11]利用 Wi-Fi 信号特征进行健身动作识别。然而,这些基于无线设备的方法容易受到各种环境因素的干扰。

基于穿戴设备的方法利用各种穿戴设备提供健身监测。文献[12]利用智能手表和智能手机中集成的惯性传感器实现了健身动作识别和重复动作计数。文献[13]提出了基于压敏运动垫的健身监测方法,用于识别用户的动作类型并检测错误的健身姿势。

考虑到可穿戴设备抗环境干扰能力强和其在健身领域中的广泛运用<sup>[14]</sup>,本文选择可穿戴设备方法进行健身动作识别。其中,运动护膝因其能有效减轻关节负荷、提升稳定性和辅助训练等特点,成为运动员训练中的常用工具<sup>[15]</sup>。基于此,本文将惯性测量单元(IMU)集成于运动护膝中,为用户提供更安全、更实用的健身监测方案。

然而,之前基于可穿戴设备的健身动作识别方法依赖于集中收集数据,其中标注的传感器数据包含个人敏感信息,存在违反相关数据隐私法规(如欧洲《通用数据保护条例》)的风险。联邦学习(FL)<sup>[16]</sup>通过共享模型参数而非用户数据<sup>[17]</sup>,实现了全局模型与本地客户端的协同学习,成为一种保护隐私安全的有效方案。但是,传统的联邦学习容易受到用户数据异质性的影响<sup>[18]</sup>,这种异质性源于个体的身体差异和行为习惯,可能导致训练收敛缓慢并影响模型准确性<sup>[19]</sup>。此外,以前的方法通常采用集中式训练方法<sup>[20]</sup>,导致模型往往难以适应新用户。

为了应对以上挑战,本文提出了一种基于个性化联邦学习的健身动作识别方法,其利用 IMU 的可穿戴运动护膝来实现健身动作类型和用户表现水平的识别。其中,用户表现水平识别除了识别所进

行的健身动作类型,还识别动作的运动范围。在本文方法中,首先通过跨用户的联邦学习对共享的全局嵌入网络进行元训练,生成的信号表征被输入到每个本地客户端独有的分类网络中,从而获得个性化分类模型。为了训练共享的嵌入网络,本文将每个用户视为一个独立任务,每个任务均具有其独特的数据分布。具体地,本文采用 Reptile<sup>[21]</sup>(一种一阶元学习算法),以联邦方式对全局嵌入网络进行元训练,使其适应多样化任务分布,并具备对新任务的良好泛化能力。在本地客户端,嵌入网络采用三元组损失函数,在其本地数据集上进行迭代更新,并将更新后的网络推送至服务器进行聚合。通过采用三元组损失函数,缩小相似样本在嵌入空间中的距离,同时扩大不相似样本之间的距离,有效提高了所学习的嵌入表征的判别能力。在获得可泛化的信号表征后,本文设计两阶段适应策略,以完成个性化健身分类预测。首先,在本地客户端的数据集上使用三元组损失微调嵌入网络;之后,对嵌入网络和输出层进行联合微调,以实现个性化预测。通过该适应策略,模型能够实现对新用户的快速适应。最终,本文在来自 10 名志愿者、包含 6 类健身动作、有近 24 000 个动作的真实数据集上进行大量实验。结果表明,本文方法能够准确识别健身动作类型和用户表现水平。本文的主要贡献如下:

1) 本文提出一种基于可穿戴运动护膝和个性化联邦学习的健身动作识别方法,该方法不仅能有效保护用户隐私数据,还能实现对新用户的适应。

2) 实现了健身动作类型和用户表现水平的识别,帮助用户了解自身健身情况,从而提升训练效果。

3) 在真实用户数据集上进行广泛的实验。结果表明,本文健身识别方法实现了 100% 的健身动作类型识别准确率和 95.94% 的用户表现水平识别准确率,优于其他先进方法。

## 1 基于个性化联邦学习的健身动作识别方法

### 1.1 总体概述

本文提出了一种基于个性化联邦学习的健身动作识别方法,其整体框架如图 1 所示。该方法主要由 3 个模块组成,即数据采集、动作分割和健身识别。首先,利用可穿戴运动护膝对 6 类健身动作进行数据采集;之后,将采集的每组健身数据分割为多组重复动作,提高健身识别的效果;最后,将分割后的健身数据输入模型进行健身动作类型和用户表现水平识别,从而帮助用户了解和提升自身的健身表现。




图 1 本文方法整体框架

Fig.1 The overall framework of the method in this paper

1.2 数据采集

1.2.1 设备介绍

本文利用集成 IMU 的可穿戴运动护膝,对用户健身过程进行监测。传感器采样频率为 96 Hz。表 1 列出了传感器的具体参数。

表 1 传感器参数信息

Table 1 Parameter information of the sensor

| 参数                       | 加速计                              | 陀螺仪                    |
|--------------------------|----------------------------------|------------------------|
| 方向                       | 3 轴                              | 3 轴                    |
| 测量范围                     | $\pm 8\text{ g}/\pm 24\text{ g}$ | $\pm 2\text{ 000 dps}$ |
| 工作温度/ $^{\circ}\text{C}$ | 0~40                             | 0~40                   |

1.2.2 数据采集实验

实验共招募了 10 名受试者(6 名男性和 4 名女性)参与数据采集。在数据采集过程中,受试者被要求穿戴运动护膝进行健身锻炼。如图 2 所示,2 个 IMU 被嵌入到运动护膝的大腿和小腿位置,收集来自受试者的 6 类健身动作。




图 2 传感器分布

Fig.2 Sensors layout

健身动作主要分为两大类,即基于膝盖弯曲角度的动作和基于抬腿高度的动作。对于基于膝盖弯曲角度的动作,即下蹲(Squat)、弓步(Lunge)和站姿腿弯曲(Standing Leg Curl),受试者以  $10^{\circ}$  为区间,进行从  $30^{\circ}\sim 90^{\circ}$  的基于膝盖弯曲角度的健身动作。对于基于抬腿高度的动作,即站姿抬腿(Standing Leg Raise)、站姿侧腿抬腿(Standing Side Leg Raise)和站姿提膝(Standing High Knees),受试者以 10 cm 为区间,进行 30~90 cm 的基于抬腿高度的健身动作。值得注意的是,对于站姿提膝动作,由于普遍的能力限制,受试者只

进行 30~70 cm 的抬腿高度。最终,每名受试者除站姿提膝动作完成 30 组锻炼外,其余每类动作均完成了 40 组锻炼,每组锻炼包括 10 次重复动作。最终,本文收集了来自 10 名受试者、6 类健身动作、近 24 000 次重复动作的数据。为确保实验数据的准确性,数据采集过程使用量尺和电子测角仪来测量抬腿高度和膝盖弯曲角度,并将其作为真实值。图 3 和图 4 分别展示了 6 类健身动作和测量工具。




图 3 健身动作

Fig.3 Fitness actions




图 4 测量工具

Fig.4 Measurement tools

1.3 动作分割

为了准确识别健身动作类型和用户表现水平,本文采用了短时能量(STE)<sup>[22]</sup>将每组健身动作分割为多组重复动作。一个重复动作是指一组健身动作的单个完整动作周期,一组健身动作通常由多个重复动作组成。

1.3.1 短时能量计算

首先,本文对原始传感器数据采用截止频率为 4.8 Hz 的一阶巴特沃斯低通滤波器进行滤波,以抑制运动过程中的高频噪声,同时保留信号中与运动特征相关的低频成分。

之后,通过计算线性加速度幅值(MLA),即无

重力加速度,以估计健身动作的线性加速度。MLA 计算公式如下:

$$MLA(i) = \sqrt{(a(i)_x)^2 + (a(i)_y)^2 + (a(i)_z)^2} - g \quad (1)$$

式中: $a(i)_x$ 、 $a(i)_y$  和  $a(i)_z$  分别是第  $i$  个样本沿 IMU 3 个轴的加速度; $g$  表示重力加速度。在没有运动的情况下,式(1)中的 MLA 为零。

最后,使用长度为 0.5 s 的滑动窗口计算 MLA 的 STE,以 0.125 s 步长进行滑动。MLA 在时间  $t$  的 STE 可推导为:

$$E_t = \sum_{\mu=t-l+1}^t [s(\mu)\omega(t-\mu)]^2 \quad (2)$$

式中: $s(\mu)$  表示  $\mu$  时刻信号的 MLA; $\omega$  表示窗口函数; $l$  表示窗口长度。

### 1.3.2 重复动作分割

在获得 MLA 的 STE 后,对 STE 进一步研究,发现其具有独特模式:1)STE 在一个重复动作开始时迅速增加;2)STE 在重复动作中途的停顿期间存在一定程度上的降低;3)当用户返回起始位置时,STE 再次上升;4)STE 在重复动作完成时显著下降。图 5 描述了弓步运动中上述 STE 的独特模式与对应腿部重复动作之间的相关性。

基于这一发现,本文设计了一种方法来识别每次重复动作的开始和结束,其主要使用 STE 和它的一阶导数来分割重复动作。首先,分别设置开始和结束位置的一阶导数阈值为  $s_{th}$  和  $e_{th}$ ,由于每次重






图 5 弓步运动中腿部动作和 STE 模式

Fig.5 Leg movements and STE mode in lunge exercise

复动作都包括开始和结束时间,因此迭代搜索 STE 中的开始和结束时间。选择  $t$  时刻 STE 值小于 0.05 的点  $E_t$ ,并计算其一阶导数  $\xi_t = (E_{t+1} - E_t) / \Delta t$ 。如果  $\xi_t > s_{th}$ ,并且  $E_{t+2} > E_{t+1}$ ,则将第一个时间点  $t$  视为开始时间。接着,搜索时间  $t$  之后的结束时间。如果  $\xi_{t+\psi} < e_{th}$ ,并且  $E_{t+\psi-1} > E_{t+\psi}$ ,则将时间  $t+\psi$  标记为疑似结束时间。如果  $\psi < d_{th}$ ,则视  $\psi$  为相应的结束时间。其中, $d_{th}$  是经验阈值,其取决于一个重复动作内 2 个峰值之间的持续时间,峰值通过一个峰值查找算法得出。整个迭代过程会持续进行,以识别连续重复动作的开始和结束时间,直到用户完成整组锻炼。此外,通过观察发现,放在同一条腿上的 2 个 IMU 展现出相同的运动模式。为了最大限度地减少计算开销,本文将一个 IMU 的分割结果用于该腿上的另一个 IMU。图 6 展示了一组弓步运动中大腿和小腿位置上的 IMU 分割结果,该结果清晰地反映了所提方法在准确识别重复动作起止时间方面的有效性以及 2 个 IMU 之间相同的运动模式。



(a) Segmentation result of upper leg



(b) Segmentation result of lower leg

图 6 一组弓步动作的分割结果

Fig.6 Segmentation results of a set of lunge movements

在对健身数据进行分割后,本文对分割的数据样本进行一维线性插值处理,使所有数据样本的长度一致,以方便输入模型中进行训练。

### 1.4 健身识别

随着数据监管的日益严格,保护数据隐私已成为人们广泛关注的问题。尽管联邦学习在隐私保护方面取得了显著进展,但在应对人类活动识别任务中的数据异质性问题时仍面临巨大挑战<sup>[23]</sup>。此外,健身动作识别模型需要具备泛化到新用户的能力,这进一步增加了技术难度。基于这些问题,本文提

出了一种个性化联邦学习框架,在充分利用来自不同用户的异构数据的基础上,通过自适应过程,为每个用户优化生成个性化模型,实现对新用户的泛化。

#### 1.4.1 联邦表征学习

为了实现在不同用户间的有效泛化,本文在个性化联邦学习框架中同时考虑个体的相似性和异质性。每名用户被视为不同的任务,其具有独特的行为模式和本地数据集。通过优化的方式,训练从全局任务集合  $g(T)$  中采样的任务  $T$  的模型,使模型不仅适应  $g(T)$  的潜在分布,同时可以泛化到从同

一集合  $g(T)$  中采样的新任务。

健身识别任务的个性化联邦学习框架如图 7 所示,其由一个中心嵌入模型  $\theta_c$  和  $n$  个去中心化模型  $M_i$  组成,  $i \in \{1, 2, \dots, n\}$ 。特别地,嵌入网络  $\theta_c$  使用三元组损失进行元训练,以增强模型的鲁棒性,确保在数据异构的情况下保持稳定。该方法寻求

一种嵌入函数,此函数将嵌入空间中具有相同标签的数据聚类,不同标签的数据远离。通过嵌入网络生成信号表征后,将其馈送到客户端特定的分类网络中,从而允许使用其本地的数据集进行个性化的分类预测。该策略降低了为整个锻炼集合训练综合全局分类器的复杂度。




图 7 健身识别框架

Fig.7 Fitness recognition framework

算法 1 概述了用于健身识别的个性化联邦元学习方法,其包括  $n$  名用户及各自的本地数据集  $\{D_i\}$ ,  $i=1, 2, \dots, n$ 。在每一轮训练中,选择一部分用户  $U$  来更新全局参数。每个用户  $u \in U$  首先从 FL 服务器上拉取当前网络参数  $\theta_c$ ,并在其本地的数据集上执行  $n$  个周期的本地训练以获得更新的模型  $\theta_u$ 。接着,将更新的模型传输到 FL 服务器。最后,FL 服务器聚合收集到的更新  $\theta_u$ ,通过以下公式更新全局模型  $\theta_c$ :

$$\theta_{avg} = \frac{1}{|U|} \sum_{u \in U} \theta_u \quad (3)$$

$$\theta_c = \theta_c + \lambda(\theta_{avg} - \theta_c) \quad (4)$$

之后,通过执行个性化过程,为所有用户获取个性化模型,过程细节将在第 1.4.3 节讨论。

#### 算法 1 健身识别算法

输入  $n$  个用户的数据集合  $\{D_i\}$ ,  $i=1, 2, \dots, n$

输出 中心模型  $\theta_c$ , 每名用户的个性化模型

1. //元训练
2. 初始化中心模型  $\theta_c \leftarrow \theta_0$
3. for 轮次为  $1, 2, \dots$  do
4. 从所有用户中随机选取一部分用户  $U$
5. for 每名用户  $u \in U$  do
6. 从服务器拉取中心模型  $\theta_c$

7. 使用三元组损失在用户  $u$  的数据集  $D_u$  上训练  $n$  轮本地嵌入网络,获得本地化更新的参数  $\theta_u$

8. 将更新后的参数  $\theta_u$  推送给服务器

9. end

10. 根据公式  $\theta_{avg} = \frac{1}{|U|} \sum_{u \in U} \theta_u$  聚合参数更新  $\theta_c$ , 其中,  
 $\theta_c = \theta_c + \lambda(\theta_{avg} - \theta_c)$

11. 返回  $\theta_c$

12. end

13. //个性化

14. for 用户  $u$  in 所有用户 do

15. 从服务器拉取中心模型  $\theta_c$

16. 使用三元组损失在用户  $u$  的数据集  $D_u$  上微调  $\theta_c$  获得本地嵌入网络  $\theta_u$

17. 进一步使用交叉熵损失在本地数据集上微调本地分类器  $\{\theta_u, W_u\}$

18. 返回每名用户的个性化模型

19. end

#### 1.4.2 嵌入网络和三元组损失训练

嵌入网络  $\theta$  负责学习共享特征表示,该网络由卷积网络和递归网络组成。本文利用可穿戴护膝中 2 个 IMU 的 3 个轴加速度信号及加速度幅值作为特征,将其输入到嵌入网络中学习特征表示。如图 5 所示,多个 1D 卷积层(Convolutional Layer)

用于处理来自大腿和小腿的传感器数据,获取每个传感器和跨传感器的空间特征表示。首先,沿 2 个传感器的每个坐标轴分别进行卷积运算,得到各自的特征表示;接着,2 个传感器的卷积输出通过另一个卷积层进行融合,以提取它们之间的潜在相关性;之后,通过长短期记忆网络层(LSTM Layer)来获取卷积层输出的时间特征表示;最后,在嵌入网络的顶层添加一个全连接层(Fully Connected Layer),形成一个分类器,来预测各种类别的概率分布。

为了进一步增强对异构输入数据的鲁棒性,本文采用三元组损失来学习特征空间中样本之间的距离。此前,Meta-HAR<sup>[24]</sup>使用成对损失来指导嵌入网络的学习,它试图在嵌入空间中将来自同一类别的样本(正样本)聚集在一起,同时将来自不同类别的样本(负样本)分开。然而,成对损失忽略了类内差异。相比之下,三元组损失能够有效处理不同类间的相似性和相异性<sup>[25]</sup>。因此,本文采用三元组损失对嵌入网络进行训练。

三元组损失<sup>[26]</sup>已被广泛应用于各种领域,如人脸识别<sup>[27]</sup>和度量学习<sup>[28]</sup>,以优化嵌入空间。该损失函数旨在确保具有相同标签的数据点在嵌入空间中紧密聚集,同时保持不同类别数据点之间的显著分离。良好的聚类嵌入可以显著简化最终的任务。嵌入空间由  $f(x) \in \mathbb{R}^d$  表示。对于一个三元组  $t_i = (x_i^a, x_i^p, x_i^n)$ ,其中,  $x_i^a$  是锚样本,  $x_i^p$  是与锚样本同一类的正样本,  $x_i^n$  是来自不同类的负样本。三元组损失可表示为:

$$L = \sum_i^N [D(f(x_i^a) - f(x_i^p)) - D(f(x_i^a) - f(x_i^n)) + \alpha]_+ \quad (5)$$

式中:  $D$  表示欧氏距离;  $\alpha$  是正负样本对之间的强制边距,本文中设置  $\alpha = 0.3$ ;  $|\cdot|_+$  表示  $\max(\cdot, 0)$ 。

#### 1.4.3 个性化实现

为了实现对每名用户  $u$  的健身动作类型和用户表现水平识别,引入一个个性化输出层  $W_u$ ,该层与嵌入网络  $\theta_u$  相结合,形成一个完整的分类模型,由此生成的模型针对用户的特定数据集进行定制,实现个性化分类。元学习的全局嵌入网络  $\theta_c$  在发送给用户  $u$  时仅作为本地嵌入网络的初始化。之后,通过两步适应策略,对全局嵌入网络  $\theta_c$  进行适应,为每名用户获得个性化的本地分类器。首先,用户  $u$  从服务器拉取嵌入网络  $\theta_c$ ,在其本地数据集上进行微调获得  $\theta_u$ ,该过程利用式(5)中定义的三元

组损失函数对本地嵌入网络进行训练,使其适应本地数据集中存在的独特用户模式,促进嵌入信号表征的聚类。之后,使用交叉熵损失对嵌入网络  $\theta_u$  和输出层  $W_u$  一起进行微调,该过程通过在分类模型  $\{\theta_u, W_u\}$  上反向传播来最小化分类误差。最后,该方法生成了一个适应每名用户独特行为模式的个性化分类模型。

## 2 实验结果及分析

本文在来自真实世界的健身动作数据集上进行广泛实验,以评估所提方法的有效性。通过与多种先进方法的比较,验证个性化联邦学习方法的优势。

### 2.1 实验设置

首先,本文将所有用户划分为元训练用户和元测试用户。元训练用户参与元学习过程,而元测试用户作为新的参与者来评估元学习模型的泛化能力。之后,随机指定一名用户作为元测试用户,其余用户作为元训练用户,以评估所提方法和所有基线的性能。每名用户的数据集被划分为训练集(80%)和测试集(20%),为了确保实验的稳健性,共进行 5 次重复实验,实验结果取平均值。

### 2.2 实现细节

本文所有实验均在 Python 3.10 和 PyTorch 2.1.1 环境、GPU 配置 NVIDIA GeForce RTX 3090 上进行。Adam 优化器用于更新所有网络参数,其中,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.98$ ,  $\epsilon = 1 \times 10^{-8}$ 。在联邦学习过程中,本文设置  $\lambda = 1.0$ ,并在每个更新轮次执行  $n = 5$  次本地训练。

### 2.3 基线

为了验证所提方法的性能,本文将其与几个最先进的方法进行比较,包括常见的联邦学习方法和为异构数据设计的个性化联邦学习方法,具体如下:

1) Stand-alone。本地模型采取集中训练方式,不使用联邦学习方法。

2) FedAvg<sup>[16]</sup>。FedAvg 是联邦学习中最经典的方法,通过在每一轮通信中平均所有本地客户端模型参数来更新服务器参数。

3) FedBN<sup>[29]</sup>。FedBN 是一种个性化联邦学习方法,与 FedAvg 为每个客户端学习一个通用全局模型不同,其为每个客户端学习一个个性化模型,本地客户端保留批归一化层参数,不参与服务器参数聚合。

4) FedRep<sup>[30]</sup>。FedRep 是一种个性化联邦学习方法,采用层分离策略,为每个客户端学习一个共享的表征和一个独特的本地头部,其中每个客户端

交替训练底部输入层和上层的网络。

5) FedPer<sup>[31]</sup>。FedPer 是一种个性化联邦学习方法,该方法与 FedRep 类似,为每个客户端学习一个共享的表征和本地个性化层。与 FedRep 不同,FedPer 同时训练所有层的参数。

6) Meta-HAR<sup>[24]</sup>。Meta-HAR 是一种个性化联邦学习方法,以联邦的方式元训练共享表征,并使用基于余弦相似度的成对损失来增强共享表征学习,保留本地化头部,为每个用户适配个性化模型。

## 2.4 健身识别结果

健身识别包括 2 个任务,即健身动作类型识别和用户表现水平识别。前者对正在进行的健身动作类型进行识别,而后者除了识别正在进行的健身动作类型,还识别动作的运动范围。具体地,本文以膝盖弯曲角度和抬腿高度来衡量动作的运动范围,运动范围越大,表示动作执行得越标准,用户表现水平越高。

健身动作类型识别任务的比较结果如表 2 所示,最优结果加粗标注。可以观察到,在元训练用户上,所有方法在该识别任务中都取得了不错的性能,即使对于未参与训练的新用户也是如此。因为该任务只涉及 6 种健身动作类别,并且在分割重复动作后,每个样本都包含一个完整重复动作周期的训练数据,从而实现了更好的性能。对于元测试用户,由于 Meta-HAR 和本文采取了元学习的方式训练网络,因此取得了最佳性能,而其他方法则出现了一定程度的性能下降。

表 2 健身动作类型识别结果对比

Table 2 Comparison of fitness action type recognition results

| 方法          | 识别准确率       |             | % |
|-------------|-------------|-------------|---|
|             | 元训练用户       | 元测试用户       |   |
| Stand-alone | 100.00±0.00 | 99.52±0.25  |   |
| FedAvg      | 100.00±0.00 | 98.02±1.35  |   |
| FedRep      | 99.99±0.00  | 96.66±1.31  |   |
| FedPer      | 99.99±0.00  | 96.63±2.38  |   |
| FedBN       | 100.00±0.00 | 98.87±0.46  |   |
| Meta-HAR    | 100.00±0.00 | 100.00±0.00 |   |
| 本文方法        | 100.00±0.00 | 100.00±0.00 |   |

用户表现水平识别任务的比较结果如表 3 所示。与健身动作类型识别任务相比,该任务具有更多类别,更具挑战性,所有方法的性能都表现出明显下降。对于元训练用户来说,由于数据异构性,个性化联邦学习方法普遍优于传统的联邦学习方法 FedAvg,这证明了个性化方法在解决数据异构性挑

战时的有效性。Stand-alone 方法由于采用了集中式训练方法,能够更好地适应本地数据分布,因此性能最佳。对于没有参加训练的元测试用户,本文方法表现出了最佳的性能,Meta-HAR 次之,其他方法则表现欠佳,说明本文方法在应对数据异质性时具有优越性,同时对新用户具有良好的泛化能力。

表 3 用户表现水平识别结果对比

Table 3 Comparison of user performance level recognition results

| 方法          | 识别准确率      |            | % |
|-------------|------------|------------|---|
|             | 元训练用户      | 元测试用户      |   |
| Stand-alone | 95.53±0.31 | 54.04±1.49 |   |
| FedAvg      | 85.50±0.45 | 53.09±1.48 |   |
| FedRep      | 83.24±0.47 | 45.85±1.42 |   |
| FedPer      | 85.87±0.41 | 51.75±3.08 |   |
| FedBN       | 91.63±0.18 | 51.93±2.18 |   |
| Meta-HAR    | 90.88±0.42 | 92.55±0.98 |   |
| 本文方法        | 94.58±0.27 | 95.94±0.75 |   |

## 2.5 本地训练轮次探究结果

本文针对联邦学习过程中本地训练轮次对模型性能的影响进行探究实验,分别采取本地训练轮次(3, 5, 10)对所提方法进行评估,图 8 展示了方法在健身动作类型和用户表现水平识别任务中的实验结果。本文方法和 Meta-HAR 在健身动作类型识别任务中都取得了较好的结果,这证明了为每位用户获得个性化模型的有效性,尤其是在简单任务上。对于用户表现水平识别任务,本文方法在所有本地训练轮次设置下都优于 Meta-HAR。此外,在本地训练轮次设置为 5 时,本文方法在两项识别任务上的总体表现优于本地训练轮次为 3 时的表现,且达到了与本地训练轮次为 10 时相同的效果。基于训练开销和任务表现的综合考量,本文选择本地训练轮次  $n=5$ 。

## 2.6 两阶段适应策略探究结果

为评估两阶段适应策略的有效性,本文在用户表现水平识别任务上探究不同微调方式对模型性能的影响。表 4 给出了一阶段适应和两阶段适应的实验结果。在一阶段适应策略中,元测试用户在拉取服务器嵌入网络参数后,使用交叉熵损失直接对本地嵌入网络和输出层进行联合微调。而两阶段适应策略在对本地分类模型微调前,对本地嵌入网络使用三元组损失进行微调。通过观察发现,两阶段适应策略在元训练用户和元测试用户上的表现均优于一阶段适应策略,说明在对本地分类模型微调前先对本地嵌入网络进行微调,能够更好地适应本地数据分布,优化最终的分类表现。




图 8 不同本地训练轮次对模型性能的影响

Fig. 8 The impact of different local training epochs on model performance

表 4 不同适应策略对模型性能的影响

Table 4 The impact of different adaptation strategies on model performance

| 适应策略  | 元训练用户             | 元测试用户             |
|-------|-------------------|-------------------|
| 一阶段适应 | 94.06±0.42        | 94.37±0.97        |
| 两阶段适应 | <b>94.58±0.27</b> | <b>95.94±0.75</b> |

### 3 结束语

本文提出一种基于可穿戴运动护膝和个性化联邦学习的健身动作识别方法,帮助用户了解自身锻炼表现并提升健身效果。该方法以联邦的方式元训练一个全局嵌入网络,并结合适应化过程为每位用户生成本地个性化分类模型,其在保护用户隐私的同时,显著提升了模型对新用户的泛化能力。在真实世界的健身动作数据集上进行实验,结果表明,该方法实现了 100% 的健身动作类型识别准确率和 95.94% 的用户表现水平识别准确率。与基线方法相比,本文方法在识别准确率和新用户适应性方面表现更佳。在未来,将进一步聚焦于健身动作质量的评估,以支持细粒度的健身指导和锻炼损伤预防。

#### 参考文献

- [1] KIM H M, KIM M, CHO I. Home-based workouts in the era of COVID-19 pandemic: the influence of fitness YouTubers' attributes on intentions to exercise[J]. Internet Research, 2023, 33(3): 1157-1178.
- [2] 郭天晓, 胡庆锐, 李建伟, 等. 基于人体骨架特征编码的健身动作识别方法[J]. 计算机应用, 2021, 41(5): 1458-1464.
- [3] CHEN D X, ZHANG B. A home fitness satisfaction model for Chinese residents during the COVID-19 pandemic based on SEM analysis[J]. Frontiers in Public Health, 2022, 10: 947223.
- [4] Wearables shipments worldwide 2028 [EB/OL]. [2024-10-05]. <https://www.statista.com/statistics/437871/wearables-worldwide-shipments/>
- [5] NEWSOME A M, BATRAKOULIS A, CAMHI S M, et al. 2025 ACSM worldwide fitness trends: future directions of the health and fitness industry[J]. ACSM'S Health & Fitness Journal, 2024, 28(6): 11-25.
- [6] GANESH P, IDGAHI R E, VENKATESH C B, et al. Personalized system for human gym activity recognition using an RGB camera [C] // Proceedings of the 13th ACM International Conference on Pervasive Technologies Related to Assistive Environments. New York, USA: ACM Press, 2020: 1-7.
- [7] RISHAN F, DE SILVA B, ALAWATHUGODA S, et al. Infinity yoga tutor: yoga posture detection and correction system[C] // Proceedings of the 5th International Conference on Information Technology Research (ICITR). Washington D. C., USA: IEEE Press, 2021: 1-6.
- [8] 方建波, 陶烨豪, 尚杰. 基于智能可穿戴设备的复杂人体活动识别方法设计[J]. 传感器与微系统, 2023, 42(7): 87-89, 93.
- [9] FANG J B, TAO Y H, SHANG J. Design of complex human activity recognition method based on intelligent wearable devices [J]. Transducer and Microsystem Technologies, 2023, 42(7): 87-89, 93. (in Chinese)
- [10] XIE Y C, JIANG R Z, GUO X N, et al. mmFit: low-effort personalized fitness monitoring using millimeter wave[C] // Proceedings of the International Conference on Computer Communications and Networks (ICCCN). Washington D. C., USA: IEEE Press, 2022: 1-10.
- [11] LI S J, LI X, LV Q, et al. WiFit: ubiquitous bodyweight exercise monitoring with commodity Wi-Fi devices[EB/OL]. [2024-10-05]. <https://ieeexplore.ieee.org/document/8560092>.
- [12] ZHU Y, WANG D, ZHAO R, et al. FitAssist: virtual fitness assistant based on WiFi[C] // Proceedings of the 16th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services. New York, USA: ACM Press, 2019: 328-337.
- [13] GUO X N, LIU J, CHEN Y Y. FitCoach: virtual fitness coach empowered by wearable mobile devices [EB/OL]. [2024-10-05]. <https://ieeexplore.ieee.org/document/8057208>.
- [14] ZHOU B, SUH S, REY V F, et al. Quali-mat: evaluating the quality of execution in body-weight exercises with a

- pressure sensitive sports mat[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2022, 6(2): 1-45.
- [14] NEWSOME A M, REED R, SANSONE J, et al. 2024 ACSM worldwide fitness trends: future directions of the health and fitness industry[J]. ACSM'S Health & Fitness Journal, 2024, 28(1): 14-26.
- [15] MOHD SHARIF N A, GOH S L, USMAN J, et al. Biomechanical and functional efficacy of knee sleeves: a literature review[J]. Physical Therapy in Sport, 2017, 28: 44-52.
- [16] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data [EB/OL]. [2024-10-05]. <https://cse.buffalo.edu/~kaiyiji/cse701/fedavg.pdf>.
- [17] 张红艳, 张玉, 曹灿明. 一种解决数据异构问题的联邦学习方法[J]. 计算机应用研究, 2024, 41(3): 713-720.  
ZHANG H Y, ZHANG Y, CAO C M. Effective method to solve problem of data heterogeneity in federated learning[J]. Application Research of Computers, 2024, 41(3): 713-720. (in Chinese)
- [18] SOZINOV K, VLASSOV V, GIRDZIJAUSKAS S. Human activity recognition using federated learning[EB/OL]. [2024-10-05]. <https://deatkh.github.io/papers/08672262.pdf>.
- [19] 宋华伟, 李升起, 万方杰, 等. 非独立同分布场景下的联邦学习优化方法[J]. 计算机工程, 2024, 50(3): 166-172.  
SONG H W, LI S Q, WAN F J, et al. Federated learning optimization method in non-IID scenarios [J]. Computer Engineering, 2024, 50(3): 166-172. (in Chinese)
- [20] ZHANG C, REN X R, ZHU T, et al. Federated Markov logic network for indoor activity recognition in Internet of Things[J]. Knowledge-Based Systems, 2022, 253: 109553.
- [21] NICHOL A, ACHIAM J, SCHULMAN J. On first-order meta-learning algorithms [EB/OL]. [2024-10-05]. <https://arxiv.org/abs/1803.02999>.
- [22] JALIL M, BUTT F A, MALIK A. Short-time energy, magnitude, zero crossing rate and autocorrelation measurement for discriminating voiced and unvoiced segments of speech signals [C] // Proceedings of the International Conference on Technological Advances in Electrical, Electronics and Computer Engineering (TAECE). Washington D.C., USA: IEEE Press, 2013: 208-212.
- [23] YU H Z, CHEN Z K, ZHANG X, et al. FedHAR: semi-supervised online learning for personalized federated human activity recognition [J]. IEEE Transactions on Mobile Computing, 2023, 22(6): 3318-3332.
- [24] LI C L, NIU D, JIANG B, et al. Meta-HAR: federated representation learning for human activity recognition[C] // Proceedings of the Web Conference 2021. New York, USA: ACM Press, 2021: 912-922.
- [25] MUSGRAVE K, BELONGIE S, LIM S N. A metric learning reality check [EB/OL]. [2024-10-05]. <https://arxiv.org/abs/2003.08505>.
- [26] WEINBERGER K Q, SAUL L K. Distance metric learning for large margin nearest neighbor classification [EB/OL]. [2024-10-05]. <https://jmlr.csail.mit.edu/papers/volume10/weinberger09a/weinberger09a.pdf>.
- [27] SCHROFF F, KALENICHENKO D, PHILBIN J. FaceNet: a unified embedding for face recognition and clustering[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Washington D.C., USA: IEEE Press, 2015: 815-823.
- [28] HOFFER E, AILON N. Deep metric learning using triplet network [EB/OL]. [2024-10-05]. <https://arxiv.org/abs/1412.6622>.
- [29] LI X X, JIANG M R, ZHANG X F, et al. FedBN: federated learning on non-IID features via local batch normalization [EB/OL]. [2024-10-05]. <https://arxiv.org/abs/2102.07623>.
- [30] COLLINS L, HASSANI H, MOKHTARI A, et al. Exploiting shared representations for personalized federated learning [EB/OL]. [2024-10-05]. <https://arxiv.org/abs/2102.07078>.
- [31] ARIVAZHAGAN M G, AGGARWAL V, SINGH A K, et al. Federated learning with personalization layers [EB/OL]. [2024-10-05]. <https://arxiv.org/abs/1912.00818>.

文字编辑 吴云芳

栏目编辑 赖玉玲