

通过设备端少量样本学习在可穿戴人类活动识别中连接泛化和个性化研究

PIXI KANG, Tsinghua University, Sanechips Technology Co.,Ltd., China

JULIAN MOOSMANN, ETH Zürich, Switzerland

MENGXI LIU, DFKI, Germany

BO ZHOU, DFKI and RPTU, Germany

MICHELE MAGNO, ETH Zürich, Switzerland

PAUL LUKOWICZ, DFKI and RPTU, Germany

SIZHEN BIAN, DFKI and RPTU, Germany

人体活动识别 (HAR) 使用可穿戴设备在近年来取得了显著进展, 然而当模型部署到新用户时, 其泛化能力仍然有限。这种性能下降主要是由于用户引起的概念漂移 (UICD), 突显了高效个性化的重要性。本文提出了一种混合框架, 该框架首先跨用户进行泛化, 然后使用少量样本学习直接在设备上快速适应个别用户。通过仅用特定于用户的数据显示更新分类层, 我们的方法实现了稳健的个性化, 并且计算和内存开销极小。我们在节能的 RISC-V 架构 GAP9 微控制器上实现此框架, 并在三个不同的 HAR 场景中验证了它: RecGym、QVAR-Gesture 和 Ultrasound-Gesture。部署后适应分别获得了 3.73%、17.38% 和 3.70% 的一致准确性提升。这些结果证实, 在嵌入式平台上实现快速、轻量级且有效的个性化是可行的, 为野外可扩展且用户感知的 HAR 系统铺平了道路¹。

CCS Concepts: • **Human-centered computing** → **Interaction design**;

Additional Key Words and Phrases: 人类活动识别, 在设备学习, 少量样本学习, 个性化, 泛化

¹<https://github.com/kangpx/onlineTiny2023>

Authors' addresses: Pixi Kang, kang.pixi@sanechips.com.cn, Tsinghua University, Sanechips Technology Co.,Ltd., China; Julian Moosmann, julian.moosmann@pbl.ee.ethz.ch, ETH Zürich, Switzerland; Mengxi Liu, mengxi.liu@dfki.de, DFKI, Kaiserslautern, Germany; Bo Zhou, bo.zhou@dfki.de, DFKI and RPTU, Kaiserslautern, Germany; Michele Magno, michel.magno@pbl.ee.ethz.ch, ETH Zürich, Switzerland; Paul Lukowicz, paul.lukowicz@dfki.de, DFKI and RPTU, Kaiserslautern, Germany; Sizhen Bian, sizhen.bian@dfki.de, DFKI and RPTU, Kaiserslautern, Germany.

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than the author(s) must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from permissions@acm.org.

© 2025 Copyright held by the owner/author(s). Publication rights licensed to ACM.

ACM XXXX-XXXX/2025/8-ART

<https://doi.org/XXXXXXX.XXXXXXX>

ACM Reference Format:

Pixi Kang, Julian Moosmann, Mengxi Liu, Bo Zhou, Michele Magno, Paul Lukowicz, and Sizhen Bian. 2025. 通过设备端少量样本学习在可穿戴人类活动识别中连接泛化和个性化研究. 1, 1 (August 2025), 9 pages. <https://doi.org/XXXXXXX.XXXXXXX>

1 介绍

可穿戴人体活动识别 (HAR) 在健身跟踪 [2]、健康监测 [13] 和智能辅助系统 [26, 27] 中发挥着关键作用。这些系统依赖于嵌入智能手表、健身手环和身体佩戴节点等消费设备中的各种传感器, 收集与运动 [6]、姿势 [25] 和手势 [17] 相关的时间序列数据。随着深度学习方法的流行, 许多 HAR 模型采用了强大的架构, 并在大规模数据集上进行训练以实现跨多个用户和上下文的应用 [12, 21]。然而, 一个基本的限制仍然存在: 在广泛的人群上训练的模型通常在部署到新个体时表现不佳 [10, 20]。这种差异主要是由用户引起的概念漂移 (UICD) [3, 19] 造成的, 每个用户的独特行为特征、传感器放置和身体机制都与训练分布有所不同。这一观察结果与最近关于人体活动识别中的缩放定律的研究 [9] 一致, 这些研究表明, 向数据集中添加更多用户比单纯增加每位用户的数据量能带来更大的性能提升。作为一个普遍的结果, 泛化的人体活动识别模型在实际部署中准确度显著下降, 导致用户体验不佳并限制了此类解决方案的可扩展性 [10, 11]。

为了解决这一问题, 我们倡导一种两阶段的方法: 首先使用全部数据进行泛化以构建一个广泛适用的模型, 然后通过设备上的少量学习快速个性化。这种策略提供了一条在尊重硬件限制和隐私约束的同时实现稳健、用户感知推理的道路。我们专注于使这种适应能够在资源受限的微控制器上实现, 特别是使用 RISC-V GAP9 平台, 并用 RecGym [5] 数据集评估解决方案, 该数据集结合了惯性测量单元 (IMU) 和人体电容 (HBC) 信号来捕捉多样的健身房活动模式。本研究做出了以下关键贡献:

- 我们量化了用户引起的概念漂移在可穿戴 HAR 三种代表性场景中的影响。使用 RecGym、QVAR 和 Ultra 数据集, 当推广到未见用户时, 我们观察到了 0.74%、25.89% 和 6.00% 的准确率下降。
- 我们提出了一种高效的少样本设备端学习策略, 该策略仅使用目标用户的流数据样本来更新密集分类器层, 从而实现快速个性化并具有最小的内存开销。
- 我们实现了一个针对 GAP9 微控制器优化的实时设备端训练引擎, 使其能够以亚毫秒级延迟和每次参数更新消耗 μ 焦耳级别的能量进行适应。
- 我们证明了我们的混合方法在部署后提高了平均识别精度, 具体为 3.73% (RecGym)、17.38% (QVAR) 和 3.70% (Ultra), 验证了其在多种传感模式和活动类型中的稳健性和有效性。

2 相关工作

基于传感器的人类活动识别 (HAR) 主要依赖于惯性测量单元 (IMUs) 和基于摄像头的方法 [12, 21], 这些方法提供了丰富的信息, 但面临诸如累积漂移、遮挡和隐私问题等挑战。新型传感模态如雷达 [28]、超声波 [16] 和静电荷变化传感器 [23] 被提出以增强鲁棒性, 但这些系统仍然对用户间差异敏感, 并且通常需要大量的预处理或特定领域的模型设计。

为了应对用户引起的概念漂移 (UICD), 已经探索了迁移学习和元学习方法。诸如 [1, 19] 的工作应用领域适应技术来弥合训练用户与部署用户之间的差距, 但这些方法通常假设在重新训练过程中可以访问标记数据, 并且缺乏实用的设备上实现。其他如 [7, 18] 的研究探讨了使用 MCU 进行设备上的适应, 但他们要么专注于简化的 HAR 场景, 要么将训练限制为非常受限的模型, 影响最终准确性。

少样本适应作为一种有前景的范式, 用于解决低资源设置下的个性化问题。类似 TinyOL [24] 和 DaCapo [15] 的解决方案能够在微控制器上实现持续学习, 但主要是通过视觉或语音任务进行验证。在 [22] 中, 提出了一种使用量化潜在重放缓存的持续学习框架, 然而该方法需要额外的内存用于缓冲存储, 并且没有在实时可穿戴应用中进行评估。

从硬件角度看, STM32、MAX78000 [8] 和 GAP9 [5] 等平台为包括卷积神经网络加速器和并行计算集群在内的 AI 工作负载提供了越来越多的支持。然而, 很少有努力将硬件高效的部署与针对基于传感器的人体活动识别的实时适应相结合。

总而言之, 虽然先前的研究为模型个性化和设备上学习奠定了基础, 但在实现高效的可穿戴 HAR 设备端适应管道以及量化现实设置中泛化、个性化与能效-延迟效率之间的权衡方面仍存在差距。我们的研究通过展示一个面向设备的少样本用户适应端到端系统来解决这些局限性。

3 方法论

3.1 网络设计

我们采用了一种轻量级但有效的 1D 卷积神经网络 (1D-CNN), 专门针对可穿戴设备中的多通道时间序列数据。该模型结构分为两个不同的部分: 一个固定的特征提取器 (主干) 和一个用于个性化的可训练密集分类器。

主干网络始于一个 1D 卷积层, 接着是批量归一化、ReLU 激活函数和 dropout。这之后是三个残差块, 每个块都包含带有快捷连接的卷积层, 以保留时间信息同时减少梯度消失。输出然后被展平并传递给分类器。

分类器是一个单密集层后跟 softmax 激活函数。在设备上的适应过程中，仅更新这一层，允许以低内存占用实现快速个性化。这种结构确保了通用特征得以保留，同时用户特定的变化可以在少量样本情况下学习到而无需全面重新训练。

图 1 可视化了这一架构。这种一般成分和个人成分的分离受到了先前领域适应框架成功案例的启发，并在我们的评估中被证明是有效的。




Fig. 1. 网络拓扑。(a) 整个网络。(b) 残差块。

3.2 设备端学习引擎

为了在受限环境中实现实时用户适应，我们设计并实现了一个针对 GreenWaves Technologies 的 GAP9 平台优化的设备端学习引擎。GAP9 是一款低功耗并行处理器，具有多核 RISC-V 集群和专门用于信号处理和神经网络负载的硬件加速器。其内存层次结构包括 1.6MB 的 L2 SRAM 和 128KB 紧密耦合的 L1 内存，使我们能够以资源高效的方式运行训练和推理任务。我们的设备端引擎围绕减少内存访问和计算开销的理念构建，并支持对最终分类层进行高效的随机梯度下降 (SGD) 更新 (图 2)。在运行时，神经网络的主干保持冻结在 L2 内存中，仅用于前向推理。可训练的密集层以及用于动量优化的相关指数移动平均 (EMA) 缓冲区存储在 L1 内存中，以便快速更新而无需频繁的数据传输。当有新的用户样本可用时，GAP9 控制器协调通过固定主干的前向传递，使用交叉熵损失计算密集层的梯度，并进行原地参数更新。所有 L2 和 L1 之间的内存移动都预先使用 AutoTiler 脚本编译完成，计算内核在集群中的 8 个 RISC-V 核心上并行运行。这种多线程更新例程确保参数适应不仅准确而且延迟高效。




Fig. 2. 在 GAP9 处理器上实现的片上训练引擎架构

4 实验设置

4.1 数据集

为了评估我们的少样本设备端个性化策略的有效性和通用性，我们使用了三个公开的基于传感器的人体活动识别数据集：RecGym、QVAR和 Ultra-Gesture。这些数据集代表了不同的传感模式和活动类型，使得能够广泛地评估用户引起的概念漂移和适应效果。**回收 gym**[4] 在健身房锻炼期间捕捉来自可穿戴 IMU 和人体电容（HBC）的多模态数据。它包含 10 名参与者执行 12 种结构化练习的记录，通过佩戴在手腕上的设备收集。**质量变量** [23] 是一个使用 QVAR 传感器结合 IMU 的手势识别数据集。数据是从 20 名用户执行 10 种手势中收集的。**超** [14] 包含基于超声波的手势数据集，包括 7 名用户执行 8 种不同动态手势的 5,600 个样本。

4.2 预处理和输入格式化

The raw signals are segmented using a sliding window approach with a window size of 2 seconds and 50% overlap, resulting in time-series tensors with shape $(C \times T)$ where C is the number of channels and T denotes time steps. Normalization is applied per channel to remove sensor-specific biases. These segments are used for both offline training and on-device personalization without any handcrafted feature extraction, ensuring the process remains fully learnable and end-to-end.

4.3 评估协议

我们采用留一用户法（L1PO）交叉验证策略来模拟现实世界的部署。在每个折叠中，一个参与者的数据被排除在外，用于训练并保留下来进行评估。模型首先使用剩余用户的离线数据进行训练以模拟泛化能力。为了适应性调整，目标用户 40% 的样本用于设备

上的少量样本训练（少样本学习），而剩下的 60%用于测试。这种设置反映了部署后的情况，在这种情况下有限数量的标记样本可用于快速个性化。

4.4 量化用户引起的概念漂移

为了说明对设备个性化的需求,我们在三个数据集上量化了用户引起的概念漂移(UICD)的影响：RecGym、QVAR 和 Ultra。对于每个数据集，我们比较了两种训练条件下的模型性能：一种是使用留一人员法（L1PO）的一般设置，另一种是包含测试用户的会话数据的使用留一会话法（L1SO）的 Oracle 设置。

我们的结果显示，当推广到未见过的用户时，性能一致下降：RecGym 的准确率下降了 0.74%，Ultra 下降了 6.00%，而 QVAR 的下降幅度最大，达到了 25.89%。这些发现突出了在不同感知模式和应用情境下用户特定信号模式的变异性，强调了轻量级个性化以恢复实际部署中性能的必要性。

5 结果与讨论

为了全面评估我们提出的少样本个性化框架的有效性，我们在三个不同的 HAR 数据集——RecGym、QVAR 和 Ultra——上部署了 GAP9 嵌入式平台进行实验。我们在设备端训练前后报告分类准确率和系统级指标以评估模型鲁棒性、适应质量和运行时效率。

5.1 通过个性化提高准确性

在所有三个数据集中，通用模型仅通过 Leave-One-Person-Out（L1PO）交叉验证使用非用户数据进行训练。对于每个目标用户，他们的 40%的数据用于设备上的少量个性化，而剩余的 60%保留用于测试。表 1 总结了每个数据集适应前后的平均准确率。

表 1. 设备个性化前后平均识别准确率

数据集	预 ODP 准确性	后 ODP 准确性	改进
RecGym	90.37%	94.04%	+3.73%
QVAR	67.13%	84.00%	+17.38%
Ultra	91.93%	95.69%	+3.70%

QVAR 数据集表现出最大的增益（+17.38%），这可能是由于其高用户特定信号特征和较大的用户间变异性。Ultra 和 RecGym 显示出较为温和但一致的改进，尽管它们具有较高的基线泛化性能。这些结果证实了轻量级分类器适应可以显著恢复或超过基线性能，即使模型最初是在无关用户上训练的。

在所有数据集上，个性化是通过每个样本一次前向后向传递实现的。主干网络保持冻结，确保计算和内存负载最小——展示了这种方法在实际边缘场景中的可行性。

5.2 延迟和能效

为了评估系统响应性,我们使用板载计时器测量了平均推理延迟和参数更新延迟。GAP9 上单个样本的推理大约需要 0.34 毫秒,而每次设备上的训练更新(包括前向传递、损失计算和参数调整)则在 0.07 至 0.17 毫秒内完成,具体时间取决于输入大小。

在能耗方面,每次推理消耗约 35 微焦耳,而一次完整的参数更新大约需要每个样本 4 微焦耳。这相当于训练更新的能耗比典型的 MCU 类设备(如 STM32F7)降低了超过 250 倍,后者每更新一次大约消耗 400 微焦耳。GAP9 的并行架构和内存优化的训练内核是实现这种效率的关键。

5.3 稳定性和泛化能力

用户间改进的一致性(例如,在 RecGym 数据集中从+1.99%到+4.75%)表明了稳定的泛化能力和对抗用户引起的概念漂移的韧性。值得注意的是,基线准确性较低的用户往往更能从个性化中受益,尤其是在 QVAR 中,此时用户间的变异性尤为显著。这表明,少样本适应在用户间差异大或传感器放置不一致的情况下特别有用。

此外,我们的模型在适应时无需数据缓冲或基于批处理的更新。每个传入的标记样本都可以立即用于细化分类器,使得该方法非常适合于实际穿戴设备部署中流式传输或间歇性标记的数据。

我们的系统也以完全在线的方式运行,无需批量更新或样本缓冲。每个传入的标记实例都可以立即用于个性化,在实时可穿戴设置中支持自适应学习。

6 结论

我们介绍了一种用于人体活动识别(HAR)的混合框架,该框架统一了强大的跨用户泛化能力和快速、设备端个性化。利用能量高效的 GAP9 平台上的少量样本学习,我们的系统通过直接在设备上更新预训练模型的最终分类器来迅速适应新用户,保持骨干网络冻结以提高效率。在三个多样化的数据集上进行了评估,我们的方法分别实现了部署后精度提升了 3.73%、17.38%和 3.70%。这些改进是在亚毫秒级延迟和每次更新能耗为若干 μ 焦耳的情况下实现的,表明即使在受限嵌入式硬件上也能够实现实用的实时个性化。我们的研究结果强化了这项工作的核心见解:仅靠泛化不足以使野外的 HAR 变得稳健,但与快速设备端适应相结合时,它能支持可扩展、用户感知的系统。这项工作为未来必须跨多样化用户和变化环境持续运行的同时保持严格硬件预算限制的人体活动识别应用奠定了基础。

REFERENCES

- [1] Seungyeop An, Gaurav Bhat, Serhan Gumussoy, and Umit Y. Ogras. 2023. Transfer learning for human activity recognition using representational analysis of neural networks. *ACM Transactions on Computing for Healthcare* 4, 1 (2023), 1–21.

- [2] Sizhen Bian, Vitor F Rey, Peter Hevesi, and Paul Lukowicz. 2019. Passive capacitive based approach for full body gym workout recognition and counting. In *2019 IEEE International Conference on Pervasive Computing and Communications (PerCom)*. IEEE, 1–10.
- [3] Sizhen Bian, V. F. Rey, S. Yuan, and P. Lukowicz. 2022. The contribution of human body capacitance/body-area electric field to individual and collaborative activity recognition. *arXiv preprint arXiv:2210.14794* (2022).
- [4] Sizhen Bian, Vitor Fortes Rey, Siyu Yuan, and Paul Lukowicz. 2025. Hybrid CNN-Dilated Self-attention Model Using Inertial and Body-Area Electrostatic Sensing for Gym Workout Recognition, Counting, and User Authentication. *arXiv preprint arXiv:2503.06311* (2025).
- [5] Sizhen Bian, Xiaojian Wang, Tommaso Polonelli, and Michele Magno. 2022. Exploring automatic gym workouts recognition locally on wearable resource-constrained devices. In *2022 IEEE 13th International Green and Sustainable Computing Conference (IGSC)*. IEEE, 1–6.
- [6] Sizhen Bian, Siyu Yuan, Mengxi Liu, Hans Schotten, and Paul Lukowicz. 2025. A Magnetic Field-based Ubiquitous 3D Tracking System With Physics-informed Deep Supervision Neural Network. (2025).
- [7] Marco Craighero, Davide Quarantiello, Benedetta Rossi, Davide Carrera, Pietro Fragneto, and Giacomo Boracchi. 2023. On-device personalization for human activity recognition on STM32. *IEEE Embedded Systems Letters* (2023).
- [8] Analog Devices. 2023. *MAX78000 User Guide*. <https://www.analog.com/media/en/technical-documentation/user-guides/max78000-user-guide.pdf>.
- [9] Tom Hoddes, Alex Bijamov, Saket Joshi, Daniel Roggen, Ali Etemad, Robert Harle, and David Racz. 2025. Scaling laws in wearable human activity recognition. *arXiv preprint arXiv:2502.03364* (2025).
- [10] Jenni Hokka. 2024. Gender and the diversity of the human body as challenges for the inclusive design of wearable technology. *Fashion Practice* 16, 1 (2024), 108–133.
- [11] Michelle Holko, Tamara R Litwin, Fatima Munoz, Katrina I Theisz, Linda Salgin, Nancy Piper Jenks, Beverly W Holmes, Pamela Watson-McGee, Eboni Winford, and Yashoda Sharma. 2022. Wearable fitness tracker use in federally qualified health center patients: strategies to improve the health of all of us using digital health devices. *NPJ Digital Medicine* 5, 1 (2022), 53.
- [12] C. Hou. 2020. A study on IMU-based human activity recognition using deep learning and traditional machine learning. In *2020 5th International Conference on Computer and Communication Systems (ICCCS)*. IEEE, 225–234.
- [13] Sheikh MA Iqbal, Imadeldin Mahgoub, E Du, Mary Ann Leavitt, and Waseem Asghar. 2021. Advances in healthcare wearable devices. *NPJ Flexible Electronics* 5, 1 (2021), 9.
- [14] kangpx. 2023. 40khz-ultrasonicDHGR-onlineSemi. <https://github.com/kangpx/40khz-ultrasonicDHGR-onlineSemi> original-date: 2022-12-14T08:54:14Z.
- [15] Omar Khan, Gyeong Park, and Euiyoung Seo. 2023. DaCapo: An On-Device Learning Scheme for Memory-Constrained Embedded Systems. *ACM Transactions on Embedded Computing Systems* 22, 5s (2023), 1–23.
- [16] Kai Ling, Hanjun Dai, Yuanchao Liu, Alex X. Liu, Wei Wang, and Qiang Gu. 2022. UltraGesture: Fine-Grained Gesture Sensing and Recognition. *IEEE Transactions on Mobile Computing* 21, 7 (2022), 2620–2636.
- [17] Mengxi Liu, Daniel Geißler, Deepika Gurung, Hymalai Bello, Bo Zhou, Sizhen Bian, Paul Lukowicz, and Passant Elagroudy. 2025. iBreath: Usage Of Breathing Gestures as Means of Interactions. *arXiv preprint arXiv:2507.04162* (2025).
- [18] N. Llisterri Giménez, M. Monfort Grau, R. Pueyo Centelles, and F. Freitag. 2022. On-device training of machine learning models on microcontrollers with federated learning. *Electronics* 11, 4 (2022), 573.
- [19] A. Mathur. 2020. *Scaling machine learning systems using domain adaptation*. Ph.D. Dissertation. UCL (University College London).
- [20] Aws Saood Mohamed, Nidaa Flaih Hassan, and Abeer Salim Jamil. 2024. Real-Time Hand Gesture Recognition: A Comprehensive Review of Techniques, Applications, and Challenges. *Cybernetics and Information Technologies* 24, 3 (2024), 163–181.
- [21] Francisco Javier Ordóñez and Daniel Roggen. 2016. Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition. *Sensors* 16, 1 (2016), 115.
- [22] Lorenzo Ravaglia, Marco Rusci, Davide Nadalini, Andrea Capotondi, Francesco Conti, and Luca Benini. 2021. A TinyML Platform for On-Device Continual Learning with Quantized Latent Replays. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems* 11, 4 (2021), 789–802.
- [23] Eric Reinschmidt, Christian Vogt, and Michele Magno. 2022. Realtime hand-gesture recognition based on novel charge variation sensor and imu. In *2022 IEEE Sensors*. IEEE, 1–4.

- [24] Haoze Ren, Darko Anicic, and Thomas A. Runkler. 2021. TinyOL: TinyML with online-learning on microcontrollers. In *2021 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 1–8.
- [25] Francesca Salaorni, Giulia Bonardi, Federico Schena, Michele Tinazzi, and Marialuisa Gandolfi. 2024. Wearable devices for gait and posture monitoring via telemedicine in people with movement disorders and multiple sclerosis: a systematic review. *Expert review of medical devices* 21, 1-2 (2024), 121–140.
- [26] G. Saleem, U. I. Bajwa, and R. H. Raza. 2023. Toward human activity recognition: a survey. *Neural Computing and Applications* 35, 5 (2023), 4145–4182.
- [27] R. Singh, A. K. S. Kushwaha, and R. Srivastava. 2023. Recent trends in human activity recognition – a comparative study. *Cognitive Systems Research* 77 (2023), 30–44.
- [28] Fan Zhou et al. 2024. FourierKAN-GCF: Fourier Kolmogorov-Arnold Network–An Effective and Efficient Feature Transformation for Graph Collaborative Filtering. *arXiv preprint arXiv:2402.00000* (2024).

Received 06 February 2025; revised XX XX 2025; accepted XX XX 2025