

## 基于主动学习和 Wi-Fi 感知的人体识别系统

赵广智<sup>1</sup>, 周志鹏<sup>1</sup>, 龚伟<sup>1</sup>, 陈绍青<sup>1</sup>, 周浩泉<sup>2</sup>

(1. 中国科学技术大学, 安徽 合肥 230026; 2. 中国科学技术大学附属第一医院(安徽省立医院), 安徽 合肥 230001)

**摘要:** 基于深度学习和 Wi-Fi 感知的人体行为识别系统已逐步成为主流的研究方向, 在近年来得到了长足的发展。然而, 现有的系统严重依赖于大量带标记样本以达到良好的识别精度。这导致了大量的人力成本用于标记数据, 同时现有系统也难以应用于实际场景。针对该问题, 提出一种将主动学习应用于 Wi-Fi 感知的人体行为识别系统——ALSensing。该系统是第一个将主动学习和 Wi-Fi 人体行为识别相结合的系统, 能够利用有限数量的已标记训练样本构建一个性能良好的行为识别器。利用商用的 Wi-Fi 设备实现了 ALSensing 系统, 并且使用 6 个不同场景的实际数据集评估了它的性能。实验结果显示, ALSensing 利用 3.7% 的已标记训练样本能够达到 52.83% 的识别精度, 利用 15% 的已标记训练样本能够达到 58.97% 的识别精度, 而利用现有基于深度学习的人体行为识别系统测量的参考基准在 100% 的已标记训练样本的情况下达到 62.19% 的识别精度。可见, ALSensing 能够实现与现有基于深度学习的人体行为识别系统接近的识别精度, 但是所需要的已标记训练样本的数量大幅度减少。

**关键词:** 主动学习; 人体行为识别; Wi-Fi

**中图分类号:** TP393

**文献标志码:** A

**doi:**10.11959/j.issn.2096-3750.2022.00262

## Human activity recognition system based on active learning and Wi-Fi sensing

ZHAO Guangzhi<sup>1</sup>, ZHOU Zhipeng<sup>1</sup>, GONG Wei<sup>1</sup>, CHEN Shaoqing<sup>1</sup>, ZHOU Haoquan<sup>2</sup>

1. University of Science and Technology of China, Hefei 230026, China

2. The First Affiliated Hospital of USTC(Anhui Provincial Hospital), Hefei 230001, China

**Abstract:** Human activity recognition system based on deep learning and Wi-Fi sensing has gradually become the mainstream research field and has been developed in recent years. However, related systems heavily rely on training with huge labeled samples to reach a high accuracy, which is labor-intensive and unrealistic for many real-world scenarios. To solve this problem, a system that combines active learning with Wi-Fi based human activity recognition—ALSensing was proposed, which was able to train a well-perform classifier with limited labeled samples. ALSensing was implemented with commercial Wi-Fi devices and evaluated in six real environments. The experimental results show that ALSensing achieves 52.83% recognition accuracy using 3.7% of total training samples, 58.97% recognition accuracy using 15% of total training samples, while the existing full-supervised system reaches 62.19% recognition accuracy. It demonstrates that ALSensing has a similar performance with baseline but requires much less labeled samples.

**Key words:** active learning, human activity recognition, Wi-Fi

### 0 引言

人体行为识别系统已经逐渐成为一个计算机

科学的重要研究课题, 相关研究成果也逐步地应用于生产生活的各个方面, 如运动追踪<sup>[1]</sup>、辅助生活<sup>[2]</sup>、安全监控<sup>[3]</sup>以及医疗健康<sup>[4]</sup>等。人体行为

收稿日期: 2021-09-22; 修回日期: 2022-02-08

通信作者: 周浩泉, zhouhq2005@qq.com

基金项目: 合肥市自主创新政策“借转补”项目(No.J2020Y03)

**Foundation Item:** The Independent Innovation Policy Program of Hefei(No.J2020Y03)

识别系统通过分析包含人体行为的数据达到辨识人类活动的目的, 进而辅助人类解决各类实际问题。因此, 人体行为识别系统可以被粗略的划分为感知人体行为, 即利用视觉、传感器等设备采集包含人体行为的数据, 以及辨识人体行为, 即使用手工建模、机器学习模型等方法判断输入数据的对应行为。目前的人体行为识别系统, 根据不同的感知方式, 可以大致分为以下3类。

### 1) 基于视觉的人体行为识别系统

此类系统利用摄像头等视觉设备采集包含人体行为的视频数据进而辨识人体行为。文献[5]以帧为单位, 将每帧视频划分为多个区域, 生成更细致的人体骨骼图运动轨迹, 进而识别人体行为。然而, 此类系统存在3个明显的缺陷。第一, 辨识精度受光源影响。当存在障碍物遮挡或者可见光较弱时, 摄像头等视觉设备受环境光源的影响较大, 难以获得可靠的数据, 从而降低辨识的精度。第二, 存在潜在的隐私风险。以摄像机作为感知的方式, 被监测人员或者场景的真实状况可能会暴露在多个环节, 存在涉及个人隐私的风险, 可部署场景因此受限。第三, 模型性能非常依赖已标记训练样本数量。在视频数据中, 针对同一个目标的同一个动作, 不同的着装或不同的场景均会影响辨识的精度, 因此需要大量已标记训练数据保证模型性能。

### 2) 基于可穿戴设备的人体行为识别系统

此类系统主要通过目标人员穿戴的专用传感器设备(如加速度计、温度计、压力计等)感知人体行为。文献[6]利用腕带传感设备感知目标人员的行为活动, 将单个人的行为组合视为个人的独特标识, 从而识别目标人员身份。此类系统相比于基于视觉的人体行为识别系统, 不受环境光源的束缚, 能够获得诸如运动轨迹、温度等更加丰富的数据信息, 但是依然存在3个局限。第一, 系统的部署成本较高。此类系统采集人体行为数据需要目标人员穿戴专用的传感器设备, 这些设备增加了部署的经济成本较高。第二, 设备有依赖性与局限性。一套传感器设备通常专用于某一任务或者某一场景, 更换任务或者更换场景时, 则需要更换设备。第三, 系统需要频繁维护电源。某些小型的基于可穿戴设备的人体行为识别系统, 在工作时需要频繁地交互数据, 因此, 电能消耗迅速, 需要经常补充或更换电源。

### 3) 基于无线信号的人体行为识别系统

此类系统利用目标人员存在或者运动对无线信号的信号强度、信道质量等参数造成的影响区分相应的动作。文献[7]利用射频信号监测用户的睡眠姿势, 避免不良睡姿引发的病情恶化。此类系统相比于基于视觉、可穿戴设备的人体行为识别系统, 放宽了对环境光源、专用设备的要求, 避免了个人隐私问题, 降低了部署成本。无线信号中的 Wi-Fi 信号, 部署广泛、应用普遍, 能够有效减少系统的经济成本。另外, Wi-Fi 信号可以是正交频分复用(OFDM, orthogonal frequency division multiplexing)信号, 能提供更准确的行为信息。针对上述分析, 综合考虑系统的部署成本和实际应用, 本文尝试利用 Wi-Fi 信号作为此工作的行为感知媒介。

在采集到行为数据后, 人体行为识别系统的下一步工作则是通过分析数据特征辨识对应的人体行为。在早期的人体行为识别系统研究工作中, 一般采用手工特征提取和传统机器学习统计模型相结合的方式分辨对应的人体行为<sup>[8]</sup>。然而, 此类方法需要工作人员具备对应数据领域的专业知识, 如处理视频数据需要视频处理的相关知识, 处理无线信号数据需要信号处理领域的知识, 这严重阻碍了人体行为识别系统的发展。随着深度学习的出现, 许多人体行为识别系统研究工作尝试利用深度学习模型自动地从原始数据提取数据特征、辨识对应的人体行为, 这使得人体行为识别系统得到了迅速发展<sup>[9]</sup>。然而, 目前大多数基于深度学习的人体行为识别系统都需要大量的已标记训练本来更新模型参数, 从而保证良好的辨识精度。这既需要花费巨大的人力标注数据, 又不便于系统在实际环境部署。换言之, 对已标记训练样本的大量需求极大地限制了人体行为识别系统从研究到应用的转化。本文受到主动学习思想的启发, 尝试利用主动学习作为人体行为识别系统的辨识模型, 以便解决当前对已标记训练样本的需求问题。因此, 本文提出了一个名为 ALSensing(active learning sensing)的人体行为识别系统, 它能够实现与现有基于深度学习的人体行为识别系统接近的精度, 但所需要的已标记训练样本数量减少 90%左右。

本文的主要贡献有以下3个方面。

1) 本文是第一个将主动学习思想和 Wi-Fi 人体行为识别相结合的工作。这不仅为解决现有基于深

度学习的人体行为识别系统发展受已标记训练样本数量限制的问题提供了思路，而且为主动学习提供了新的应用部署场景。

2) 本文提出了 ALSensing 系统，并利用商业设备实现了 ALSensing 系统，它兼顾主动学习和 Wi-Fi 人体行为识别的优势，能够实现与现有基于深度学习的人体行为识别系统相当的精度，但所需要的已标记训练样本大幅度减少。

3) 本文利用 6 个真实环境的数据集量化地评价了 ALSensing 系统的性能。在相同的数据集下，ALSensing 利用 3.7% 的已标记训练样本能够达到 52.83% 的识别精度，利用 15% 的已标记训练样本能够达到 58.97% 的识别精度，而利用现有基于深度学习的人体行为识别系统测量的参考基准在 100% 的已标记训练样本的情况下为 62.19% 的识别精度。

### 1 ALSensing 系统

ALSensing 系统能够利用 Wi-Fi 信号感知人体行为，然后通过相应的处理识别出对应的行为内容，ALSensing 系统工作流程如图 1 所示。

从设计过程来看，可将 ALSensing 系统分为 3 个部分，ALSensing 系统框架如图 2 所示。行为感知是 ALSensing 系统采集原始数据的功能模块，数据处理是 ALSensing 系统处理原始数据的功能模块，模型训练是 ALSensing 系统中构建辨识模型的功能模块。

### 2 ALSensing 系统的行为感知

行为感知模块是 ALSensing 系统获取人体行为数据的功能模块，该模块能够采集包含人体行为的原始 Wi-Fi 数据。本文分析现有基于无线信号的人体行为识别系统的研究工作，直观的想法是利用 Wi-Fi 接收端的信号作为原始的输入数据，然后再进行后续的处理工作。为实现 Wi-Fi 信号感知人体行为的功能，当前要解决的问题，一个是选择 Wi-Fi 信号的哪些参数表征人体行为，另一个是如何在实际场景中采集 Wi-Fi 数据并标记。

#### 2.1 Wi-Fi 信号参数的选择

基于无线信号的人体行为识别系统一般选择接收信号强度 (RSS, received signal strength) 或者信道状态信息 (CSI, channel state information) 等信号参数表征人体行为。前者常用于早期的研究工作，后者则逐渐地应用于近期的研究工作。据信号处理的研究工作可知，在多径效应中，CSI 比 RSS 有更强的抗干扰能力，在感知、定位应用方面 CSI 的粒度比 RSS 的粒度更精细。根据此现状综合 Wi-Fi 信号的特点，本文决定使用 CSI 作为 ALSensing 系统的表征参数以便推测对应的人体行为。在商用的 Wi-Fi 设备应用中，一般多个接收天线和多个发送天线组成多输入多输出 (MIMO, multiple input multiple output) 系统。在这样的系统中，每一对接收天线和发送天线可以

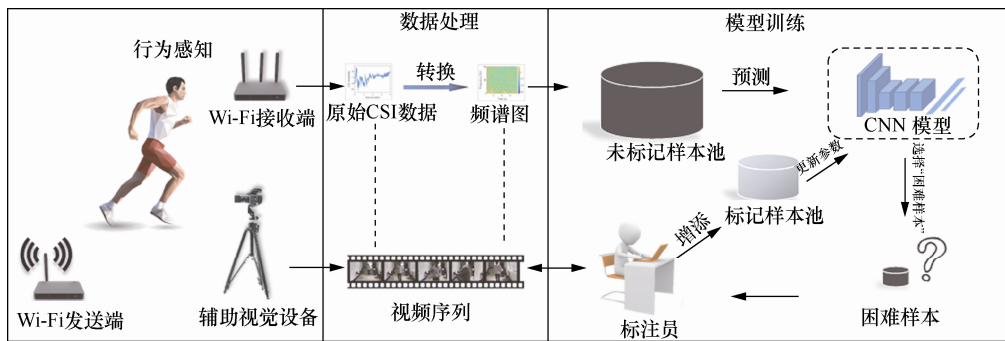


图 1 ALSensing 系统工作流程




图 2 ALSensing 系统框架

视为一个信道, 因此可以建模为

$$\mathbf{Y} = \mathbf{H} \cdot \mathbf{X} + \mathbf{N} \quad (1)$$

其中,  $\mathbf{Y}$  是接收信号的向量,  $\mathbf{X}$  是发送信号的向量,  $\mathbf{N}$  是噪声的向量,  $\mathbf{H}$  是信道矩阵。因为噪声常常可以建模为循环对称复正态分布, 所以  $\mathbf{H}$  的近似值可以作为 CSI 的估计值。

$$\hat{\mathbf{H}} = \frac{\mathbf{Y}}{\mathbf{X}} \quad (2)$$

另外, 由于 Wi-Fi 信号是 OFDM 信号, 因此可以得到载波层次的 CSI, 单载波 CSI 为

$$H_i = |H_i| e^{j\sin\theta} i \in [1, S_c] \quad (3)$$

其中,  $i$  是载波的序号,  $S_c$  为载波的数量,  $|H_i|$  为载波的幅值,  $\theta$  为载波的相位。

## 2.2 数据的采集与标记

确定表征人体行为的信号参数后, 需要解决如何在实际中采集数据。本文采用两个 Wi-Fi 设备分别作为接收端和发送端, 当目标人员出现或者活动在两个设备组成的无线电场中, Wi-Fi 信号传播的直接路径便会受到阻碍, 从而形成信号的反射、折射或者信号衰减等。这种表现会直接地体现为信号参数 CSI 的变化, 通过分析 CSI 的变化便可以推测出相应的人体行为。然而, 利用这种方式虽然能够得到包含人体行为的原始数据, 但是主动学习框架中的标注员却无法直接对数据进行标记, 其根本原因是无法区分数据内容, 自然图像与信号图像对比如图 3 所示。图 3(a) 为日常所见的自然场景, 肉眼很容易判断图中的人体行为。图 3(b) 和图 3(c) 为信号处理常用的 CSI 波形图和时频图, 即便是信号处理领域的专家也无法用肉眼分辨 CSI 数据所代表的行为。而现有的基于无线信号的人体行为识别研究工作在采集数据时, 一般是研究人员与目标人员以在线的方式采集, 即采集数据时两类人员同时在场。研究人员在现场根据目标人员的行为即刻做好标记而不是在模型训练时标记。这种在线的

标记方法使得人体行为识别系统难以移植到其他场景或者其他任务, 另外这种提前预知的方式并不符合实际应用的需求。因为在实际应用中, 研究人员与目标人员通常是离线状态, 无法提前预知目标人员的行为, 因此只能在模型训练阶段或者数据处理阶段, 根据数据的内容而不是采集时的预知信息对数据进行标记。

针对如何进行离线标记无线信号数据的问题, 本文受 Dina Katabi 等<sup>[10]</sup>的工作启发, 设计实现了一种离线的采集与标记方法。如图 1 行为感知部分所示, 该方法部署两个 Wi-Fi 设备分别作为接收端和发送端 (接收端有 3 根全向天线, 发送端有一根全向天线), 一个视觉设备作为辅助以便记录目标人员的视频数据。在数据采集完成后, 根据时间信息建立 Wi-Fi 数据和视频序列的映射关系。当标注员标记样本时, 依靠映射关系, 将 Wi-Fi 数据对应的视频序列反馈给标注员。通过视频序列, 标注员可以很轻松地获知 Wi-Fi 数据对应的行为, 从而对样本进行标记。值得注意的是, 在这里视频序列仅作为标记样本的辅助, 并不参与模型的训练。

得益于此, ALSensing 系统对同步的要求不高, 跑步与走路动作示意图如图 4 所示。假如现在有两个动作, 每个动作可以切分为 10 帧。当以 Wi-Fi 数据包的时间戳为参考标准, 即便人工或者设备造成了同步误差致使视频序列前 2 帧遗失或损坏, 标注员仍然能够根据剩余长度的视频序列判断对应动作, 因此降低了采集数据时的操作难度以及对视觉设备的要求。

## 3 ALSensing 系统的数据处理

在行为感知模块采集到包含人体行为的原始 Wi-Fi 数据后, 并不能直接将原始数据用于模型训练, 因为原始的 Wi-Fi 数据包含大量的由环境变化造成的或设备固有的噪声。因此, 在模型训练前仍




图3 自然图像与信号图像对比



图4 跑步与走路动作示意图

需要对数据进行进一步的处理。

采用深度学习等智能化去噪方法需要大量的数据训练模型，这会增加系统训练成本，并不符合本文的初衷。因此，本文采用传统的信号处理方法以便平滑原始的 Wi-Fi 数据。本文首先利用 Hampel 滤波器消除原始 CSI 数据中的异常点。Hampel 滤波器使用中位数绝对偏差估计每个样本在其窗口中位数附近的标准偏差，如果样本与中位数的差异超过一定的标准偏差，则将其替换为中位数。

然后，本文采用主成分分析法处理数据，提取仅与人体行为相关的信号参数的变化数据。考虑初始阶段数据可能并不包含人体行为信息，因此在进行主成分分析前，去除每个数据包的这个部分。随后将每个数据包划分为 8 s 一段的多个小段，分别使用主成分分析法处理。然后再选择每个数据包排名的前 20 个主成分进行归一化。最后，将经过主成分分析法处理的数据生成的相应时频图作为模型的输入数据。利用主成分分析法，不仅可以过滤不相关的噪声使得数据更纯净，而且还可以降低数据的维度，从而减少计算成本。

在信号处理领域，常见的数据表示方式如图 3(b)和图 3(c)所示。然而，由于实际环境中的多径效应，对于 CSI 的波形图而言，相同的行为在不同的场景、时间可能会呈现不同的形状，这使得模型难以辨识。而对于时频图而言，在时域领域，CSI 受多径效应的影响相对较弱。因此，本文以时频图作为模型输入数据，利用短时傅里叶变换 (STFT, short-time Fourier transform) 将数据转化为时频图如式(4)所示。

$$\text{STFT}\{x[n]\} = X(e^{j\omega}, n) = \sum_{m=-\infty}^{\infty} x[n-m]w[m]e^{-j\omega m} \quad (4)$$

其中， $x[n]$  是信号的离散时间序列， $w[m]$  是 STFT 的窗口。因此，信号幅度平方产生的频谱图为

$$\text{Spectrogram}\{x[n]\} = |X(e^{j\omega}, n)|^2 \quad (5)$$

#### 4 ALSensing 系统的模型训练

经过数据处理模块后，需要考虑如何进行模型训练。本文的初衷是解决目前人体行为识别系统对已标记训练样本数量的依赖问题，另外，考虑主动学习旨在通过使用少量的、有限的已标记训练样本提升模型的性能<sup>[11]</sup>的特质，因此，本文的直观想法是引入主动学习进行模型训练。主动学习一般根据预设的选择策略优先选择信息最为丰富或者最难以识别的样本，这些样本也被称为“困难样本”，可以理解为对模型性能提升程度影响更加显著的样本。主动学习流程如图 5 所示，其工作步骤如下。

**步骤 1** 从未标记的样本池中随机抽选少量样本，经过标注员标记后，将这些样本添加到已标记样本池中，以便初始化模型参数。

**步骤 2** 模型参数初始化后，对未标记样本池的所有样本进行概率预测，从而获得每个样本的类别概率。

**步骤 3** 基于预测的结果，根据预设的选择策略指标，对未标记样本池的全部样本排序，从而抽取少量的、最具代表性的“困难样本”。

**步骤 4** 将被抽选出来的样本反馈给标注员进行标记，然后将其添加到已标注样本池中以便更新模型参数。在此过程中，标注员无须具备相应数据领域处理的专业知识，只要能够区分样本的类别即可。

**步骤 5** 重复步骤 2~步骤 5，直到满足截止条件或者未标记样本池为空。由此可见，主动学习不同于经典深度学习中的监督学习方法，并不侧重大量的训练标记样本来保证模型的性能，而是更加关注如何选择具有代表性的样本。

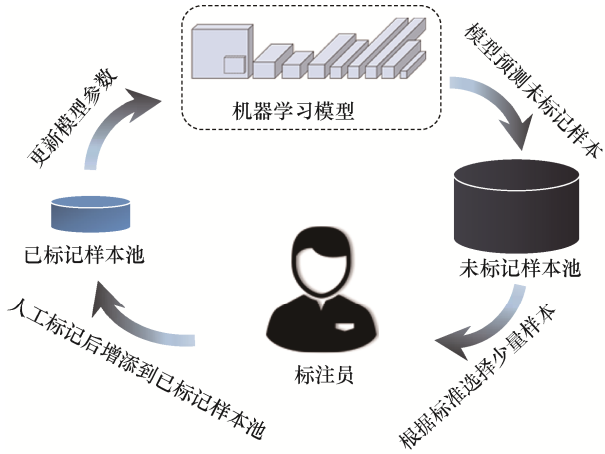


图 5 主动学习流程

本文的更多地关注主动学习能否有效解决人体行为识别系统目前对已标记训练样本数量需求的问题，而不是主动学习模型的创新，因此本文选择经典的卷积神经网络（CNN, convolutional neural network）模型 AlexNet<sup>[12]</sup>作为 ALSensing 系统的学习模型。假设拥有一个记为  $D = \{x_i\}_{i=1}^n$  的数据集， $x_i$  为一个样本，一共有  $n$  个样本。另外，用  $y_i = j$ ,  $j \in \{1, \dots, m\}$  表示  $x_i$  的标签为  $j$  类，而此时所有样本都未标记。

**初始化设置：**在模型训练开始前，本文所有样本随机地分成 3 个部分， $D_L$  表示已标记样本池（模型的训练集）， $D_U$  表示未标记样本池（等待被抽选的数据集），其余为验证集。 $D_L$  中的样本被标注员标记后用来初始化模型参数。

**选择策略：**选择策略是主动学习的关键，决定了样本抽选的指标。本文采用基于不确定性的选择策略，使用最低置信度作为样本抽选的标准，其定义为

$$LC_{x_i} = \max_j p(y_i = j | x_i; W) \quad (6)$$

其中， $LC_{x_i}$  表示  $x_i$  属于  $j$  类的可能性， $W$  为模型的参数。如果某个样本在所有类中的最大可能性都不高，那么模型将把该样本作为“困难样本”抽选出来。因此，在每次迭代中，对  $D_U$  全部样本进行概率预测，然后依据  $LC_{x_i}$  升序排列以便选择“困难样本”。

**CNN 模型参数更新：**以增量的方式更新模型参数，每轮选择  $K$  个样本进行模型参数更新。本文定义模型参数更新的损失函数为

$$\min_W -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^m 1\{y_i = j\} \lg p(y_i = j | x_i; W) \quad (7)$$

其中， $N$  表示  $D_L$  中样本数量。另外，反向传播函数是主动学习模型进行参数更新的关键函数。本文采用经典的反向传播函数，其定义推导为

$$\begin{aligned} \frac{\partial L}{\partial W} &= \frac{-\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^m 1\{y_i = j\} \lg p(y_i = j | x_i; W)}{\partial W} = \\ &= \frac{-\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^m 1\{y_i = j\} \lg p(y_i = j | x_i; W)}{\partial W} = \\ &= -\frac{1}{N} \sum_{i=1}^N 1\{y_i = j\} - p(y_i = j | x_i; W) \frac{\partial z_j(x_i; W)}{\partial W} \end{aligned} \quad (8)$$

其中， $\{z_j(x_i; W)\}_{j=1}^m$  表示第  $i$  个样本进入 SoftMax 分类器前在模型最后一层的激活函数。

完整的算法框架如算法 1 所示。

#### 算法 1 主动感知算法

输入：未标记样本池  $D_U$ ，已标记样本池  $D_L$ ，每轮抽选样本的数量参数  $K$ ，抽选“困难样本”总数量的上限 CounterM，最大迭代的周期  $T$

输出：CNN 模型的参数  $W$

用  $D_L$  初始化 CNN 模型参数  $W$

当没有达到最大的迭代周期  $T$  执行

预测未标记样本池  $D_U$  全部样本的类别概率

如果没有达到抽选困难样本总数量的上限 CounterM 那么

根据式(6)从  $D_U$  中选择  $K$  “困难样本”

待标注员标记这些“困难样本”后添加到  $D_L$

根据式(7)、式(8)利用  $D_L$  更新模型参数  $W$

否则

中断

结束循环

返回模型参数  $W$

## 5 实验评估

### 5.1 实验设置

#### 1) 实验配置

服务器主机为戴尔 T630，处理器型号为 E5-2690，显卡型号为 MIS GeForce RTX3070，内存大小为 8 GB，操作系统为 Ubuntu 16.04，框架为 PyTorch。

#### 2) 数据采集

由于目前暂无具备公信力的无线信号数据集，因

此本文召集 9 名志愿者进行数据采集工作，这些志愿者体重为 50~90 kg，他们的身高为 165~195 cm。标记这些志愿者为 1 号~9 号，要求他们在不同的场景下做出 4 种不同动作，即步行、跳跃、转身、蹲下起立。数据采集在 6 个不同的日常环境中完成，即开放平台、会议室、电梯入口、大厅、走廊和实验室，分别标记为 E1~E6，数据采集的场景如图 6 所示。



图 6 数据采集的场景

### 3) 参考基准

根据本文初衷，有两个参考基准。第一个参考基准命名为 BS\_Rd。BS\_Rd 的处理过程与 ALSensing 相似，都是以增量、循环的方式从未标记样本池  $D_U$  中选择少量的样本，然后交给标注员标记，随后添加到已标记样本池  $D_L$  去更新模型参数。唯一不同的是，BS\_Rd 并不是按照最低置信度等特定的指标抽选样本。BS\_Rd 每次以随机的方式抽选与 ALSensing 相等数量的样本，换句话说，BS\_Rd 对待所有的未标记样本是平等的。因此，可以通过对比 BS\_Rd 与 ALSensing 评估 ALSensing 系统中选择策略的有效性。第二个参考基准命名为 BS\_All。BS\_All 可以认为是现有应用了深度学习的 Wi-Fi 人体行为识别系统的方法。BS\_All 是一种全监督的方法，将所有的未标记样本进行标记，然后不断地迭代更新模型参数。因此，可以通过对比 BS\_All 与 ALSensing 评估 ALSensing 系统能否解决当前面临的标记样本数量需求问题。

### 5.2 性能评估

本文首先评估了 ALSensing 系统的整体性能，即利用包含 6 个环境、9 名志愿者的复杂数据集对比分析了 ALSensing 系统、BS\_Rd 和 BS\_All 的识别精度（同一实验中，模型识别样本类型正确的数量/样本的总数量）。因为 ALSensing 系统与 BS\_Rd 只是抽选样本的策略不同，当使用全部数据样本时，这意味着这两者只是以不同的顺序输入了一模

一样的数据集。这难以评估 ALSensing 系统中选择策略的有效性。因此，该实验设置不同的 CounterM（实验所用的参数定义同算法 1 所述）作为训练样本的数量上限，整体性能评估实验如图 7 所示。





图 7 整体性能评估实验


由图 7 可知，在相同数量的训练样本下，ALSensing 的识别精度高于 BS\_Rd。可见 ALSensing 系统中选择策略的是有效的。另外，经过统计，ALSensing 利用 3.7% 的训练样本可以实现 52.83% 的识别精度，利用 15% 的训练样本可以实现 58.97% 的识别精度，而 BS\_All 利用 100% 的训练样本仅有 62.19% 的识别精度。相比之下，ALSensing 实现了与 BS\_ALL 相比接近的识别精度，但却减少了 90% 的标记样本需求。可见 ALSensing 系统能有效解决当前面临的标记样本数量需求问题。

另外，考虑系统在实际场景的应用部署，本文测试了 ALSensing 的鲁棒性，即固定 CounterM 为 200，然后改变参数 K 值、训练批次 (batch) 的大小和训练代数 (参数定义见算法 1) 对比分析 ALSensing 在不同设置情况下的性能变化，鲁棒性的评估实验结果如图 8 所示。


由图 8 可见，与 BS\_Rd 相比，ALSensing 系统在三组实验中 (不同 K 值、batch 大小、训练代数) 识别精度均高于 BS\_Rd，换句话说，在参数改变的情况下，ALSensing 系统更为鲁棒。为进一步验证系统的鲁棒性和选择策略的有效性，分别在 E1、E3 两个环境中，用 5%、10%、15% 的单一环境数据测试系统性能，结果如图 9 所示。



(a) 不同参数K值下的识别精度




(b) 不同batch大小的识别精度




(c) 不同训练代数下的识别精度

图8 鲁棒性的评估实验结果



(a) E1环境下的对比实验



(b) E3环境下的对比实验

图9 单一环境的评估实验结果

由图9可知,在E1、E3的单一环境下,ALSensing的识别精度仍高于BS\_Rd,这意味着ALSensing在

单一环境下仍然能够保持较好的性能。另外,在5%、10%、15%等不同的数据量情况下,ALSensing的识别精度均高于BS\_Rd,这进一步证明了本文主动学习模型中选择策略的有效性。

由于本文采用主动学习模型,而模型训练过程有人工参与,所以不能以传统的复杂度分析方法直接评价本文模型复杂度。如何讨论分析主动学习的训练复杂度依旧是主动学习领域亟待解决的问题,这非本文工作范围。但在本文的实验中,对比BS\_Rd参考基准,在相同数据集下,ALSensing训练时间缩短50%左右。

## 6 结束语

综上所述,ALSensing系统能够有效地解决当前人体行为识别系统对已标记训练样本数量的需求问题。本文是第一个将主动学习和Wi-Fi人体行为识别相结合的工作,而且使用商用的Wi-Fi设备实现了ALSensing系统。同时,本文也利用真实的实验量化地评估了ALSensing系统的性能。另外,相信在未来的工作中,数据增强处理、改变模型框架等方法能够进一步提升ALSensing系统性能,使ALSensing系统更易于移植到其他任务。另外,感谢中国科学技术大学信息科学实验中心提供的软硬件服务。

## 参考文献:

- [1] 刘希文, 陈海明. 一种基于CSI的人体动作计数与识别方法[J]. 北京邮电大学学报, 2020, 43(5): 105-111.  
LIU X W, CHEN H M. A human action counting and recognition method based on CSI[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(5): 105-111.
- [2] 赵雄, 陈平, 潘晋孝. 基于骨架关键点的车内异常行为识别方法[J]. 机械与电子, 2021, 39(3): 10-15.  
ZHAO X, CHEN P, PAN J X. Recognition method of abnormal behavior in car based on skeleton key points[J]. Machinery & Electronics, 2021, 39(3): 10-15.
- [3] 冯仕民, 刘忠育, 俞啸, 等. 矿山物联网人员情境描述与不安全行为识别[J]. 物联网学报, 2018, 2(4): 93-98.  
FENG S M, LIU Z Y, YU X, et al. Workers' context description and unsafe behavior recognition in internet of things for mines[J]. Chinese Journal on Internet of things, 2018, 2(4): 93-98.
- [4] 邓颖, 吴华瑞, 孙想. 基于机器视觉和穿戴式设备感知的村镇老年人跌倒监测方法[J]. 西南大学学报(自然科学版), 2021, 43(11): 186-194.  
DENG Y, WU H R, SUN X. Design of a real-time human falling monitoring method for elderly people in villages and towns based on multi-dimensional data analysis[J]. Journal of Southwest University (Natural Science Edition), 2021, 43(11): 186-194.
- [5] CHEN K, FORBUS K. Action recognition from skeleton data via


analogical generalization over qualitative representations[EB]. 2018.

- [6] RANJAN J, WHITEHOUSE K. Object hallmarks: identifying object users using wearable wrist sensors[C]//Proceedings of UbiComp '15: Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing. 2015: 51-61.
- [7] YUE S C, YANG Y Z, WANG H, et al. BodyCompass: Monitoring sleep posture with wireless signals[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2020, 4(2): 1-25.
- [8] WANG Y X, WU K S, NI L M. WiFall: device-free fall detection by wireless networks[J]. IEEE Transactions on Mobile Computing, 2017, 16(2): 581-594.
- [9] ZHAO MM, LI T H, ALSHEIKH M A, et al. Through-wall human pose estimation using radio signals[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7356-7365.
- [10] FAN L J, LI T H, YUAN Y, et al. In-home daily-life captioning using radio signals[M]//Computer Vision – ECCV2020. Cham: Springer International Publishing, 2020: 105-123.
- [11] WANG K Z, ZHANG D Y, LI Y, et al. Cost-effective active learning for deep image classification[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 27(12): 2591-2600.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

#### [作者简介]



赵广智（1995-），男，中国科学技术大学计算机科学与技术学院硕士生，主要研究方向为主动学习、人体行为识别、无线感知等。



周志鹏（1994-），男，中国科学技术大学计算机科学与技术学院博士生，主要研究方向为机器学习、无线感知等。



龚伟（1982-），男，中国科学技术大学教授、博士生导师，主要研究方向为大规模物联网、智能感知、无线网络、分布式计算等。



陈绍青（1985-），男，博士，中国科学技术大学信息科学实验中心讲师，主要研究方向为振动主动控制、自适应控制等。



周浩泉（1968-），男，中国科学技术大学附属第一医院（安徽省立医院）副教授、硕士生导师，主要研究方向医学信息技术等。