arXiv:2301.06993v1 [cs.HC] 17 Jan 2023

你的掌中一天：基于智能手机加速度计的复杂活动识别

Emma Bouton–Bessac、Lakmal Meegahapola 和 Daniel Gatica-Perez

Idiap研究所，瑞士；EPFL，瑞士

摘要。 人类活动识别（HAR）能够实现上下文感知用户体验，让移动应用程序根据用户的活动调整内容和交互方式。因此，智能手机已成为人类活动识别的重要工具，因为它们能够支持大规模、多样化的数据收集。尽管以往的人类活动识别研究利用惯性传感器（即加速度计）以较高的准确率检测简单活动（如坐姿、步行、跑步），但复杂日常活动的识别仍是一个尚未解决的问题，尤其是在远程工作/学习场景中，人们的活动更加久坐。此外，了解一个人的日常活动有助于开发旨在促进其身心健康的应用程序。本文研究仅使用智能手机加速度计数据识别复杂活动。我们使用了一个大型智能手机感知数据集，该数据集在疫情期间从五个国家的600多名用户中收集而来。研究结果表明，采用深度学习的二元分类方法，利用部分个性化模型，可对八种复杂活动（睡眠、进食、观看视频、在线交流、听讲座、体育活动、购物、学习）进行分类，AUROC分数最高可达0.76。这一结果展现了令人鼓舞的前景，表明在后疫情时代，仅凭手机加速度计数据评估复杂活动是可行的。

关键词： 智能手机感知、人类活动识别、加速度计、深度学习

1 引言

在人类活动识别（HAR）中，可以识别步行、跑步、坐姿、 [.....],烹饪、驾驶等各种人类活动。数据可以从可穿戴设备上的传感器或加速度计收集，也可以通过视频帧或图像获取[9]。借助加速度计、陀螺仪或位置等感知模态中的传感器数据，便可以实现人类活动识别 [17] [21]。根据 Pl¨otz 等人 [17],的研究，人类活动识别面临的主要挑战是数据匮乏，以及数据质量和标注质量不佳。智能手表等新近设备能够为人类活动识别提供高质量数据。例如，Laput 等人 [10] 使用智能手表，以较高准确率对 25 种复杂手部活动进行分类。然而，与智能手机相比，智能手表的普及率低得多；根据 Coorevits 等人 [5], 的研究，大多数人使用智能手表和可穿戴设备六个月后便会停止使用。

鉴于智能手机无处不在，使用智能手机进行人类活动识别前景可期：超过 80% 的人拥有智能手机，这有助于简化数据收集并增加数据量。数据收集可以覆盖不同人群，也可以持续进行。由于智能手机配备了多种传感器，收集到的数据类型丰富多样，例如加速度计、陀螺仪、光传感器、磁场、应用使用情况、打字和触摸事件等[14]。多种感知模态还可以用于识别进食 [13] 和饮水 [4], 等复杂活动，甚至识别情绪 [19]等复杂心理状态。由于年轻成年人拥有智能手机的比例很高，利用智能手机促进他们身心健康的做法也日益普及 [15] 。了解一个人的日常活动有助于开发改善心理健康的应用程序。此外，使用来自不同国家的数据时，需要考虑不同的文化、人群、传感器质量以及携带智能手机的方式（口袋、背包、钱包等）。因此，来自多个国家的数据应具有更好的泛化能力，但也会带来额外挑战。使用多种感知模态虽然能提供丰富信息，但可能会增加电池续航时间方面的成本。因此，人们正致力于仅使用低成本惯性传感器进行人类活动识别 [2]。

以惯性传感器进行人类活动识别的既有研究，主要致力于推断相对简单的活动，例如步行、坐姿、爬楼梯和睡眠 [3,8]。然而，识别复杂活动在多种场景中都很有帮助，例如老年护理和患者追踪 [10,18] ，以及习惯追踪（例如帮助人们戒烟 [10]）。此外，由于疫情，大多数人的日常生活变得更加久坐，使人类活动识别任务更具挑战性，因为智能手机加速度计所提供的信息可能更少。

在这项工作中，我们试图回答以下研究问题（RQ）：仅使用原始加速度计数据，能否利用疫情期间（远程研究环境）收集的数据识别复杂日常活动？为回答这一研究问题，我们作出了两项贡献：

贡献 1：我们考察了一个真实生活中的智能手机感知数据集，其中包含来自五个国家的 637 名大学生所提交的逾 21.6 万份自我报告。该数据集是在疫情期间连续四周收集的。我们进行了描述性数据分析，以识别参与者报告的最常见复杂活动。

贡献 2：我们针对八种复杂日常活动定义并评估了二元推断模型：睡眠、进食、学习、听讲座、在线交流与社交媒体、观看视频或电视、体育活动和购物。这些活动都体现了年轻成年人日常生活的不同方面。我们仅使用原始加速度计数据和深度学习，结果表明，总体层面模型可达到 0.51–0.62 的 AUROC 分数，而混合模型可将其提升至 0.56–0.76。

据我们所知，我们的研究有助于理解如何仅利用智能手机加速度计数据来推断复杂活动，例如我们在此研究的活动。疫情背景推动了远程办公和久坐生活方式，因此值得对这一情境展开研究。本文

结构如下：第2节介绍相关研究；第3节和第4节分别阐述研究方法与结果。最后，第5节讨论主要发现，并在第6节总结全文。

2 背景与相关工作

2.1 智能手表与人类活动识别

用于人类活动识别的可穿戴设备。Laput 等人 [10] 成功使用智能手表捕捉精细的手部活动。研究涉及 25 种手部活动，例如拍手、饮水或开门。该方法结合快速傅里叶变换和卷积神经网络，对这 25 种手部活动的准确率达到 95.2%。这项工作可用于追踪吸烟等习惯，或应用于老年人护理监测系统。其缺点之一是用户必须将设备佩戴在优势手臂上，而智能手表通常佩戴在非优势手臂上。将智能手表佩戴在非优势手臂上进行人类活动识别更具挑战性，但也更贴近日常生活。Straczkiewicz 等人 [22], 指出的另一项智能手表相关挑战是，约有 15.6% 的人未遵循有关智能手表佩戴位置的数据收集规程，例如将手表佩戴在“错误”的手臂上。这项研究表明，人类活动识别的数据收集可能极具挑战性，因为仅仅将传感器佩戴在非理想的手臂上，就会降低性能。这些结果同样适用于实际应用：如果传感器佩戴位置不当，检测到的活动就可能不准确。

用于人类活动识别的智能手机与智能手表。 Raihani 等人 [16] 表明，在识别基本活动（坐姿、步行、跑步）时，将加速度计放在口袋里与戴在手腕上，分类器的性能不相上下。从长远来看，智能手机具有实际优势，因为许多用户在几个月后便不再使用智能手表 [5]。使用智能手机进行人类活动识别，效率可以与使用可穿戴设备相当；而且，由于智能手机的拥有率高于智能手表，可用于识别的数据也更多。此外，结合智能手机传感器与腕戴式运动传感器，比仅使用智能手表更有效 [20]。这类研究评估了基本活动，也评估了吸烟、骑自行车或喝咖啡等更复杂的活动。结果表明，结合手机和手表的传感器可将性能提升 21%，总体 F1 指标达到 96%。然而， [20] 中的研究是在实验室环境中开展的，将其应用于真实场景时，性能可能会有所降低。

2.2 智能手机与人类活动识别

传感器与特征 智能手机传感器可用于推断各种人类活动和状态。例如，可根据社交互动数据推断情绪 [11]。短信、电子邮件和所用应用程序的数量等特征会被输入

各种机器学习模型，以评估用户情绪。经过为期两个月的个性化训练后，该方法的准确率达到 93%。Guvensan 等人[7] 使用智能手机的加速度计、陀螺仪和磁力计传感器来判断交通方式。采用有监督学习方法时，该方法的准确率达到 95%。Hassan 等人 [8] 从智能手机的陀螺仪和加速度计中提取特征（均值、频率偏度、平均能量），并将其输入深度置信网络。该方法在基本活动（步行、坐姿、上楼/下楼）以及两种活动之间的转换上的准确率达到 89.61%。Wu 等人 [23] 让参与者以不同速度进行相同活动，并采集加速度计数据。他们的方法在爬楼梯时的准确率为 52%–79%，坐姿识别准确率最高达到 100%；加入陀螺仪数据后，性能提升了 3.1%–13.4%。DellaMea 等人 [12] 使用智能手机的加速度计来推断家务活动，例如在计算机前工作、熨衣服或扫地。即使手机放在口袋里，他们提出的方法仍能达到 80% 以上的准确率。这为支持以下假设提供了初步证据：仅凭手机的加速度计也可以识别复杂活动。

复杂活动 Ranasinghe 等人 [18] 将复杂活动定义为一系列简单动作。这些动作由操作步骤组成，而操作步骤是构成动作的基本步骤。例如，复杂活动“派对”可以分解为“与朋友见面”“进入酒吧”和“点饮料”等动作。这些动作又可以进一步分解为“推门把手”或“拿起玻璃杯”等操作步骤。复杂活动可能包括与物体或个人的互动（例如进食、在线交流和参加派对），且持续时间较长。人类活动识别可以监测老年人的复杂活动，并改善他们的生活质量。医疗监测应用也是一个很有前景的领域。与以往经常使用身体传感器的研究相比，仅使用智能手机来识别活动不会对用户造成干扰 [24]。尽可能减少传感器的使用量，可以节省电池电量，也能更高效地利用内存。不过，这样做也更具挑战性，因为可用数据会减少，而且对于某些复杂活动而言，这些数据可能不够有意义。

我们的研究与以往研究在推断的活动类型和使用的传感器方面有所不同。我们旨在仅使用在日常生活中采集的原始加速度计数据，推断学习或进食等复杂活动。与使用实验室环境中采集的数据训练的人类活动识别模型相比，这使推断更具挑战性。此外，如第3节所述，由于数据集是在 COVID-19 疫情期间采集的，因此也带来了挑战，因为不同活动的加速度计数据可能会非常相似。因此，研究复杂活动识别模型在疫情期间采集的数据上的表现具有创新性。

3 方法

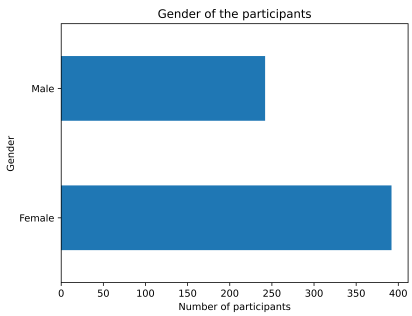
3.1 数据集

本研究使用的匿名化数据是欧盟“地平线2020”项目 WeNet [6] 的一部分。数据于2020年秋季采集。原研究旨在衡量大学生社会实践及相关日常行为的多样性，并结合移动端调查和智能手机传感器数据。该研究在奥尔堡大学（丹麦）、伦敦政治经济学院（英国）、蒙古国立大学（蒙古）、亚松森圣母升天天主教大学（巴拉圭）和特伦托大学（意大利）开展。

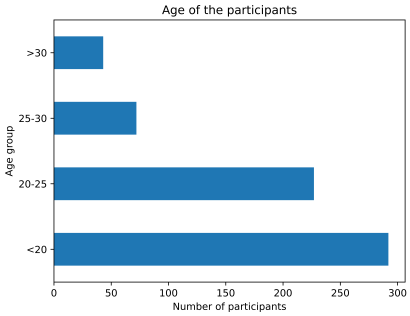
一组志愿学生参与了为期四周的数据收集。数据收集人员通过电子邮件联系了参与综述的各所大学的全体在校学生 [1]。参与者同意处理其个人数据、同意参加研究并同意接受联系，且使用搭载安卓 6.0 或更高版本系统的智能手机后，通过移动应用填写了时间日记 [1]。参与者中女性占 61%，平均年龄为 22 岁（见图 1）。在这四周内，应用每小时发送一次通知，请参与者填写时间日记（也称为自我报告），报告当前活动以及本文未使用的其他变量。如果参与者无法填写问卷，可以稍后补填（例如，醒来后可以填写自己过去几小时一直在睡眠）。学生在研究结束时获得了奖励。活动列表根据社会学领域以往的综述研究确定。与此同时，应用从 34 个传感器收集数据，例如加速度计、陀螺仪、电池电量、应用使用情况等。本文仅使用原始加速度计数据（也可以使用其他传感器数据，但本文的重点是加速度计数据，因此未予考虑）。经过数据预处理和筛选后，共有约 40K 份自我报告可供分析。

3.2 数据准备

类别选择。 图 2a 显示了数据集中每项活动的事件数量。类别不平衡严重并不令人意外，但这意味着并非所有活动都有足够的数据：旅行 在五个国家中总共只有 19 个事件，不足以让模型进行学习。因此，由于数据不足，本研究未纳入电影、戏剧、音乐会、爱好、艺术、欢乐时光／饮酒、其他娱乐、娱乐展览、文化和旅行 。其他活动未予考虑，是因为范围过于宽泛：个人护理、游戏、社交生活或志愿工作都涵盖许多可能的复杂活动。像无特别活动、休息和其他 这样的活动过于笼统，因此不值得推断。此外，我们决定合并一些类别：购物 和其他购物 合并为购物；而



(a) 数据集的性别分布。

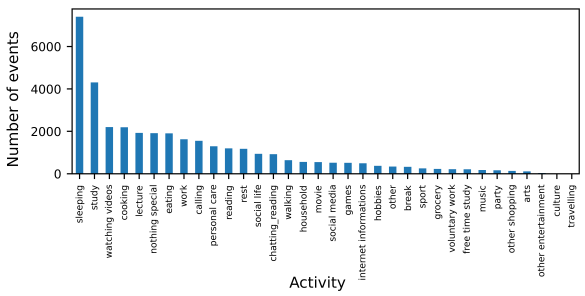


(b) 数据集的年龄分布。

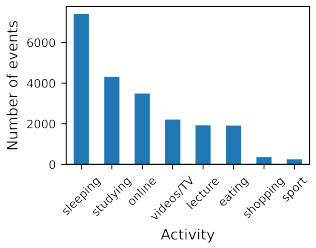
图 1：数据集的性别和年龄分布。

打电话、 聊天／阅读、 阅读互联网信息以及社交媒体合并为在线交流与社交媒体。

经过这一处理，最终保留了八个类别：睡眠、进食、学习、听讲座、在线交流与社交媒体、观看视频/电视、体育活动、购物。它们的分布如图 2b 所示。这八个类别仍然足够多样且具体，可以用于训练。此外，它们也是大学生日常复杂活动中颇具意义的案例。其中许多会直接影响健康（睡眠、进食、参加体育活动），还有一些会间接影响健康（在线交流与社交媒体、学习），因此值得通过推断这些活动来了解年轻成年人的身心健康。



(a) 整个数据集中每项活动的报告数量。



（b）每种活动的报告数量，适用于最终活动列表。

图 2：每种活动的报告数量。

预处理。 以往的人类活动识别研究采用 2–30 秒的时间窗口来推断基本活动 [3,20]。然而，本研究关注的活动

属于复杂活动，也就是说，它们持续时间更长 [18]；因此，仅凭几秒钟的数据可能更难识别复杂活动。这项任务的另一个方面是，参与者究竟在何时进行所报告的活动并不明确。由于他们每 30 分钟填写一次表格，因此无法确定他们是在整个 30 分钟内进行该活动，还是只在报告前或报告后进行。因此，我们假设用户会在自我报告时间（即参与者完成自我报告时的时间戳）之前的 3 分钟内某个时刻进行该活动。此外，我们还假设参与者在填写报告时不会进行所报告的活动（例如，一边跑步一边填写关于跑步的报告），因此删除了对应于这段时间的数据。于是，对数据应用了以下处理流程：

1. 对于每份用户自我报告，选取报告时间前3分钟的加速度计数据。2. 删除用户填写自我报告期间的数据。3. 将加速度计数据重新采样至数据集的平均采样频率（3.33Hz）。4. 如果报告短于600个采样点（3分钟 * 60秒 * 3.33），则丢弃该数据点。

检查后，我们发现存在大量缺失数据：尽管五个国家的数据预处理方式相同，但由于自我报告时间前后 10 分钟的时间窗口内必须有加速度计数据，因此许多事件被舍弃。蒙古和意大利的大多数报告都因没有数据而被舍弃。巴拉圭、丹麦和英国只有少量空报告。大部分数据采集自蒙古和意大利，因此数据损失相当显著：这两个国家共有 16 万份报告，而巴拉圭、丹麦和英国共采集了 3.1 万份报告。这带来了挑战，因为可用于深度学习的数据量因此减少。剩余的自我报告被重采样至数据集的平均采样频率（见图4）。我们计算了每个国家七位用户的平均采样时间，并将其四舍五入至 300 毫秒。

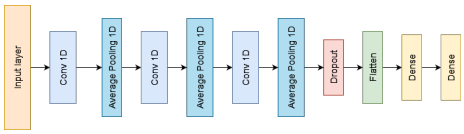


图3：模型架构。

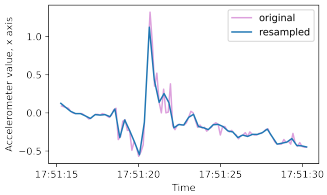


图4：丹麦一位参与者“听课”活动的加速度计数值，x轴。

3.3 深度学习

上一节讨论了如何使用每份自我报告前最后三分钟的加速度计数据。输入数据的形状为 3×600：三个加速度计轴（x、y 和 z），以及长度为 600 的数据序列。每份报告都标注了相应的活动。随后将数据输入深度学习模型。我们实现了多种架构，采用一维卷积层或长短期记忆层，并使用表现最佳的模型，如图 3 所示。由于输入数据是序列，因此采用了一维卷积层。我们也探索了长短期记忆模型，因为它通常用于处理序列数据。但在这种情况下，其效果并不优于一维卷积。此外，我们使用了 Adam优化器和二元交叉熵。采用的性能指标包括准确率、受试者工作特征曲线下面积（AUROC）和 F1分数。我们报告了这三项指标，因为准确率适用于类别平衡的情形；而在类别不平衡的情形下，采用宏平均的 AUROC 和 F1分数更为合适，因为它们对多数类和少数类给予同等权重。评估采用十折交叉验证完成。

对每个类别分别进行二元分类，例如“睡眠”和“不睡眠”。对于每个训练划分，从正类中随机选取 60% 的采样点用于训练，20% 用于验证，20% 用于测试。测试了两种设置：平衡数据和平衡数据集不平衡数据。对于平衡情况，从其他七个类别中选取数量相同的采样点。对于不平衡情况，则使用其他七个类别的全部数据。在不平衡数据集上进行训练，是为了确定是否能够推断出小众事件（不经常发生的事件）。例如，购物只占学生一周活动的一小部分，因此了解是否能够检测到购物活动很有意义。

训练是在总体层面进行的，这意味着按用户划分数据：每个用户只能属于一个集合（训练用户不会出现在验证集或测试集中）。该实验的结果将显示复杂活动识别能否在新用户上表现良好。另一项实验则按采样点划分数据：将报告随机划分为训练集、验证集和测试集。

4 结果

4.1 总体层面模型。

总体层面模型的结果见表 1。

平衡数据集。这可以视为未进行任何个性化时的基准准确率。因此，结果表明，每位用户的智能手机使用方式可能都大不相同，而且模型在新用户身上的表现不佳，需要进行个性化。睡眠的 AUROC分数最高，为 0.62。可能是因为睡眠是最主要的类别，因此有更多数据可用于训练模型。体育活动的性能低于预期，可能是因为不同用户进行体育活动时的加速度计数据各不相同。

表 1：群体层面结果：平衡和不平衡数据集的 AUROC 分数、F1分数、准确率和标准差。

活动	平衡数据集				不平衡数据集			
	AUROC	F1分数	准确率（%）		AUROC	F1分数	准确率（%）	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差
睡眠	0.62	0.04	0.56	0.20	58.2	2.1	0.62	0.05	0.63	0.14	92.2	4.2
进食	0.51	0.03	0.79	0.13	50.9	2.1	0.51	0.03	0.01	0.01	88.8	2.3
学习	0.55	0.03	0.59	0.21	53.0	2.2	0.57	0.04	0.11	0.09	74.3	4.5
听课	0.52	0.03	0.68	0.09	51.6	2.3	0.51	0.00	0.01	0.01	89.4	1.9
在线交流	0.56	0.03	0.64	0.21	55.1	2.5	0.57	0.02	0.03	0.02	84.7	1.8
观看视频/电视	0.54	0.04	0.51	0.19	53.0	2.5	0.56	0.03	0.04	0.03	85.3	2.2
体育	0.52	0.07	0.59	0.23	50.9	7.4	0.52	0.06	0.00	0.04	97.7	1.0
购物	0.57	0.06	0.58	0.23	55.3	5.2	0.48	0.05	0.00	0.00	97.3	0.5

表2：混合结果：平衡和不平衡数据集的AUROC分数、F1分数、准确率及标准差。

活动	平衡数据集					不平衡数据集				
	AUROC		F1分数		准确率 (%)	AUROC	F1分数		准确率 (%)	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
睡眠	0.76	0.01	0.57	0.06	69.6	0.9	0.72	0.03	0.61	0.06	66.4	2.8
进食	0.57	0.04	0.59	0.30	55.3	2.6	0.56	0.04	0.71	0.26	54.3	3.9
学习	0.66	0.013	0.68	0.05	61.5	0.9	0.67	0.00	0.68	0.06	61.5	0.9
听课	0.62	0.04	0.69	0.22	58.5	3.9	0.60	0.04	0.70	0.22	57.8	3.1
在线交流	0.60	0.04	0.73	0.11	57.4	2.7	0.61	0.01	0.71	0.03	58.1	1.3
观看视频/电视	0.56	0.05	0.72	0.22	53.2	4.4	0.55	0.05	0.58	0.07	54.2	4.4
体育	0.58	0.04	0.55	0.23	55.6	3.5	0.59	0.03	0.72	0.01	56.5	3.6
购物	0.61	0.06	0.54	0.15	56.8	4.3	0.63	0.04	0.57	0.07	59.4	0.1

这也可能是由于居家训练（在 COVID-19 背景下），或者用户训练时没有把手机放在口袋里。因此，较高的活动水平未能被采集。经过一段个性化训练期后，各项指标可能会有所提高。在线交流的指标出奇地高，因为它归纳了四种不同的活动。原本可能会预期其指标较低，但由于这些活动都与手机有关，因此这样的结果也合情合理。

不平衡数据集 在这里，准确率并不能代表模型的性能。除睡眠外，所有活动的F1分数都非常低。原因在于，由于类别不平衡，模型总是预测为负类，从而导致较高的准确率和较低的F1分数。购物和体育各自占数据集的比例不超过5%，因此，如果模型只预测负类，其准确率将分别超过95%；实际情况确实如此，这也解释了F1分数较低的原因。只有睡眠的各项指标较高，因为它是最大的类别，模型因此有更多数据用于训练。采用总体层面方法无法很好地识别小众事件。对于购物，AUROC分数低于0.5，这意味着模型在某些情况下将类别颠倒了。

4.2 混合模型

混合模型的指标见表2。

平衡数据集。 由于上述原因，“睡眠”的结果最佳，AUROC分数为 0.76。此外，人们睡觉时智能手机的活动很容易识别：智能手机可能会在夜间放在床头柜上。观看视频/电视和在线交流的 F1分数较高。“进食”的各项指标较低，这可以解释为人们在进食时使用智能手机的方式可能各不相同（例如，与他人一起进食时把手机收起来、观看内容、聊天等）。人们原本会预期“体育”能取得不错的结果，但其 AUROC分数只有 0.58。观看视频/电视的指标较低，可以用观看视频与看电视之间的差异来解释。人们可以打开电视作为背景，然后用手机做其他事情（从而产生不同的加速度计活动）；而在手机上观看视频时，注意力会更加集中在手机上，产生的加速度计数据可能反映的是手机静止不动。

不平衡数据集。 如第3.3节所述，训练使用了不平衡数据集，以检验是否能够识别小众事件。与平衡数据集相比，这种情况下的 F1分数通常更高。不过，在平衡数据和不平衡数据上的 AUROC分数相近。

5 讨论

原始数据集中包含 34 种不同的活动。然而，由于原始数据集中的数据不足，大多数活动都被剔除，同时保留了八种能够反映学生生活、信息丰富且具有代表性的活动。这些活动也会影响健康，有助于了解学生的生活，并最终通过应用支持他们的身心健康。仅使用加速度计数据进行人类活动识别颇具挑战，因为活动本身复杂，而且数据收集时正值新冠肺炎疫情期间：这些活动更容易产生相似的加速度计数据。考虑到这一挑战，最终的 AUROC 和 F1 分数尚属合理。研究发现，混合模型的表现优于群体层面模型，而小众事件的识别效果较差（不平衡数据集的情况）。尽管二元分类的结果相对较低，但必须牢记实验设置：数据是在五个国家收集的，因此涵盖了不同人群、传感器质量和手机使用方式。这种多国家方法应具有良好的泛化能力，也说明有必要针对多国家数据开展更多研究。此外，后续研究可以评估各国及各传感器的数据质量，以获取更多细节。原始数据集是在现实生活条件下收集的，这也会影响数据质量和模型性能，但同时反映了模型实际应用时所处的真实环境。如前所述，每部智能手机的组件各不相同

（尤其是在不同国家／洲之间），而仅使用加速度计是合理的，因为这种传感器成本低廉，且大多数智能手机都内置加速度计。本文并未重点研究使用多种传感器，因为目标是仅使用加速度计数据。此外，原始数据集中的陀螺仪或磁力计数据不足以训练模型。只使用一种传感器还可以节省电池电量，并最大限度地减少对智能手机性能的影响，这对于健康监测应用而言尤为重要。

6 结论

在本研究中，我们将来自智能手机的原始加速度计数据输入深度学习模型，以推断复杂日常活动。对于八种复杂活动，二元分类在群体层面模型（非个性化）中取得了 0.51–0.62 的合理 AUROC 分数，在混合模型（部分个性化）中则取得了 0.56–0.76 的 AUROC 分数。本研究表明，仅使用智能手机的加速度计即可推断复杂活动，并可作为面向年轻成年人身心健康的人类活动识别多国家方法的基线。

致谢

本研究由欧盟地平线 2020 WeNet 项目资助，资助协议编号为 823783。我们还感谢 Darshana Rathnayake（新加坡新加坡管理大学）参与讨论。

参考文献

1. 多样性最终模型，https://www.internetofus.eu/wp-content/uploads/sites/38/2021/03/D1.3-Final-model-of-diversity.pdf 2. Ann, O.C., Theng, L.B.：人类活动识别：综述。载于：2014年IEEE控制系统、计算与工程国际会议（ICCSCE 2014 7072750 3 389 393 2014 10 1109 2014）。第 – 页（）。https://doi.org/ . /ICCSCE. . . Arif, M., Bilal, M., Kattan, A., Ahamed, S.I.：利用智能手机加速度传感器改进身体活动分类。《医学系统杂志》（2014），https: //doi.org/10 0 4 1007 10916 014 0095 . / s - - - . Bae, S., Ferreira, D., Suffoletto, B., Puyana, J.C., Kurtz, R., Chung, T., Dey, A.K.：利用基于智能手机的传感器检测年轻成年人的饮水事件。《ACM交互式、移动、可穿戴和普适技术汇刊》1(2)，1–36（2017）5. Coorevits, L., Coenen, T.：可穿戴健身追踪器的兴衰（08 2016）6. Giunchiglia, F., Bison, I., Busso, M., Chenu-Abente, R., Rodas, M., Zeni, M., Gunel, C., Veltri, G., de G¨otzen, A., Kun, P., Ganbold, A., Chagnaa, A., Gaskell, G., Stares, S., Bidoglia, M., Cernuzzi, L., Hume, A., Zarza, J.L., Meegahapola, L., Gatica-Perez, D.：关于日常活动与社会实践的全球多样性试点研究（2020）。特伦托大学技术报告。编号 #DISI-2001-DS-0（23），36–44（2021年4月）

7. Guvensan, M.A., Dusun, B., Can, B., Turkmen, H.I.：一种基于片段的新方法，用于提升交通方式检测的分类性能。《Sensors》**18**(1)（2018）。https://doi.org/10.3390/s18010087, https://www.mdpi.com/ 1424-8220/18/1/87 8. Hassan, M.M., Uddin, M.Z., Mohamed, A., Almogren, A.：一种利用智能手机传感器和深度学习的鲁棒人体活动识别系统。《未来一代计算机系统》**81**，307–313（2018）。https://doi.org/https://doi.org/10.1016/j.future.2017.11.029, https://www.sciencedirect.com/science/article/pii/S0167739 17317351 9 X . Jobanputra, C., Bavishi, J., Doshi, N.：人类活动识别：综述。《计算机科学程序汇刊》**155**，698–703（2019）。https://doi.org/https://doi.org/10.1016/j.procs.2019.08.100, https://www. sciencedirect.com/science/article/pii/S1877050919310166，第16届移动系统与普适计算国际会议（MobiSPC 2019）、第14届未来网络与通信国际会议（FNC-2019）、第9届国际可持续能源信息技术会议 10. Laput, G., Harrison, C.：利用智能手表感知细粒度手部活动，第1–13页。计算机协会，纽约，NY，美国（2019），https: // doi.org/10 3300568 11 1145 3290605 . / . . Likamwa, R., Liu, Y., Lane, N., Zhong, L.：Moodscope：基于智能手机使用模式构建情绪传感器（06 2013）。https://doi.org/10 2464449 12 1145 2462456 . / . . Mea, V.D., Quattrin, O., Parpinel, M.：基于智能手机加速度计识别家务活动及智能手机位置影响的可行性研究。《健康与社会护理信息学》**42**(4)，321–334（2017）。https://doi.org/10.1080/17538157.2016.1255214, https://doi.org/ 10 28005434 13 1080 17538157 2016 1255214, . / . . pMID: . Meegahapola, L., Bangamuarachchi, W., Chamantha, A., Ruiz-Correa, S., Perera, I., Gatica-Perez, D.：情境中的进食事件感知：仅使用智能手机的方法。《IEEE开放获取》**10**(文章)（2022）14. Meegahapola, L., Gatica-Perez, D.：智能手机感知与年轻成年人的身心健康：综述。《IEEE开放获取》**9**，3374–3399（2020）15. Meegahapola, L., Gatica-Perez, D.：智能手机感知与年轻成年人的身心健康：综述。《IEEE开放获取》**9**，3374–3399（2021）。https://doi.org/10 3045935 16 1109 2020 . /ACCESS. . . Mohamed, R., Zainudin, M.N.S., Perumal, T., Mustapha, N.：基于不同加速度计传感器位置的身体活动识别多标签分类（2018）17. Pl¨otz, T., Guan, Y.：移动计算中的人类活动识别深度学习。《计算机》**51**2381112 18 5 50 59 2018 10 1109 2018（），–（）。https://doi.org/ . /MC. . . Ranasinghe, S., Machot, F.A., Mayr, H.C.：关于活动识别系统在性能和评估方面应用的综述。《国际分布式传感器网络杂志》**12**(8), 1550147716665520（2016）。https://doi.org/10.1177/1550147716665520, https://doi.org/10.1177/ 1550147716665520 19. Servia-Rodr´ıguez, S., Rachuri, K.K., Mascolo, C., Rentfrow, P.J., Lathia, N., Sand- strom, G.M.：服务于心理健康的移动感知：一项大规模纵向研究。载于：第26届万维网国际会议论文集。第103–112页（2017）

20. Shoaib, M., Bosch, S., Incel, O.D., Scholten, H., Havinga, P.J.M.：使用智能手机和腕戴式运动传感器进行复杂人类活动识别。Sensors **16**(4)（2016）。https://doi.org/10.3390/s16040426, https://www.mdpi.com/ 1424-8220/16/4/426 21. Straczkiewicz, M., James, P., Onnela, J.P.：面向健康研究的基于智能手机的人类活动识别系统综述（2021）22. Straczkiewicz, M., Glynn, N., Harezlak, J.：自由生活测量期间腕戴式三轴加速度计的佩戴位置、位置和方向（05 2019）。https://doi.org/10 19092095 23 3390. /s . Wu, W., Dasgupta, S., Ramirez, E.E., Peterson, C., Norman, G.J.：使用智能手机运动传感器识别身体活动的分类准确率。J Med Internet Res **14**(5), e130（2012年10月）。https://doi.org/10.2196/jmir.2208, http: // www.jmir.org/2012/5/e130/ 24. Zhu, C., Sheng, W.：基于可穿戴传感器的手势和日常活动识别，用于机器人辅助生活。IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans **41**(3), 569–573（2011）。https://doi.org/10.1109/TSMCA.2010.2093883