

基于智能感知的人体活动识别技术

周凯月 李佳 乔树山

(中国科学院微电子研究所, 北京 100029)

摘要: 基于智能感知的人体活动识别 (Human Activity Recognition, HAR) 技术应用潜力巨大, 尤其是在健康监测、智能运动和康复训练等领域。为了分析当前人体活动识别技术水平和未来发展方向, 首先, 阐述基于可穿戴传感器的智能传感技术; 其次, 归纳对比不同模态的公开数据集; 再次, 梳理智能算法研究现状, 分析机器学习算法、深度学习算法和多模态算法在人体活动识别中的应用效果; 最后, 论述新型传感技术、感存算一体化架构及多模态方法等未来研究方向及主要挑战, 如数据多样性、算法泛化能力和隐私保护等。

关键词: 智能感知; 可穿戴传感器; 人体活动识别; 深度学习; 数据融合; 健康监测

中图分类号: TP391.4; TP212

文献标志码: A

Human Activity Recognition Technology Based on Intelligent Perception

ZHOU Kaiyue LI Jia QIAO Shushan

(Institute of Microelectronics of the Chinese Academy, Beijing 100029)

Abstract: Human activity recognition (HAR) technology based on intelligent perception has shown great application potential, especially in the fields of health monitoring, intelligent sports and rehabilitation training. In order to analyze the current level and future development direction of human activity recognition technology, firstly, the intelligent sensing technology based on wearable sensor is described. Secondly, the open data sets of different modes are summarized and compared. Thirdly, the research status of existing intelligent algorithms is summarized, and the application effects of machine learning algorithms, deep learning algorithms and multi-modal algorithms in human activity recognition are analyzed. Finally, the future research direction and main challenges of new sensing technology, integrated sensor-memory and computing architecture, and multi-modal approach are discussed, such as data diversity, algorithm generalization ability and privacy protection.

Keywords: intelligent perception; wearable sensor; human activity recognition; deep learning; data fusion; health monitoring

0 引言

智能感知在人体活动识别 (Human Activity Recognition, HAR) 技术中具有重要作用。通过融合多种传感器 (如加速度计、陀螺仪、摄像头等) 数据, 能够精准捕捉复杂的运动动作或细微的日常

行为动作, 有效避免了单一传感器的数据误差, 极大地提高了识别准确率。同时, 基于智能感知的 HAR 技术可实现人体活动的实时监测。在医疗康复领域, 能够辅助评估患者运动恢复状况; 在智能家居领域, 可依据人体活动状态自动调控设备, 精准分析动作规范程度。由此可见, 智能感知在

HAR 技术中展现出诸多优势并发挥着重要作用,而可穿戴传感器则是实现智能感知的关键载体。

当前,可穿戴传感器为医疗康复、智能交互、虚拟现实和人机协作等领域的发展提供了重要支撑^[1-3]。但是,由于硬件配置和佩戴方式较为复杂,可穿戴传感器难以得到广泛应用^[4-5]。随着微纳传感器和柔性传感器的发展,可穿戴传感器变得更加轻便、高效和智能,也更加适合日常佩戴。柔性可穿戴传感器能够紧密贴合人体皮肤,从而更加精确地捕捉人体的微小动作变化^[6]。这不仅提升了用户的体验舒适度,而且提高了数据采集的精准率。感存算一体化架构的提出和应用进一步推动了可穿戴传感器在 HAR 技术中的应用,显著提高了数据处理的效率和实时性。该架构能够实时处理和分析数据,无须依赖外部设备或服务器,有效降低了功耗和延迟^[7]。虽然 HAR 技术相关研究取得了显著进展,但现有方法仍面临诸多挑战,如传感数据的多样化处理、复杂环境下的活动识别精度、设备能耗和用户隐私保护等^[8]。此外,不同应用场景也对算法的实时性和可靠性提出了更高的要求。

在分析 HAR 技术研究背景和技术现状的基础上,首先,阐述人体活动模型,总结可穿戴传感器在 HAR 技术中的应用,并归纳不同模态的公开数据集;其次,论述常用智能算法及其优缺点和适用范围等;最后,展望基于智能感知的 HAR 技术未来发展趋势与挑战。

1 人体活动模型概述

人体活动模型的复杂性与骨骼、关节的数量及每个关节的活动自由度紧密相关^[8]。由于构建包含所有骨骼和关节的模型复杂性较高,且对系统处理性能要求更高,建模时若减少骨骼和关节数量,则可能丢失关键的活动细节。因此,模型的简化既要降低模型复杂度,又要尽可能保留人体活动的关键特征。

通过简化人体结构(如忽略肌肉和皮肤等组织),将复杂的人体活动过程简化为骨骼围绕相应关节的旋转活动组合,构建由关节和骨骼构成的人体骨架模型,包含 204 块骨骼和 78 个关节。根据不同的应用场景,得到由不同数量关节构成的人体模型。其中,关节被视为轴承,骨骼被视为刚体链杆,人体活动被视为一系列轴承与链杆的旋转和平移组合。结合人体骨骼和关节的结构及活动特性,构建一个包括关节与骨骼的层次关节链骨骼模型用以模拟人体活动^[9]。

常用的人体运动学模型如图 1 所示。以躯干为人体运动的基本架构(16 关节点模型)如图 1a 所示,结合了形体的人体运动基本架构(14 关节点模型)如图 1b 所示。根据人体骨骼模型构建的具有多层次结构的人体运动学模型(27 关节点模型)如图 1c 所示,即 Motion Capture (Mocap) 商用产品常用的人体动作捕捉模型^[10]。




图1 人体运动学模型

a) 16 关节点模型 b) 14 关节点模型 c) 27 关节点模型

2 可穿戴传感器在 HAR 中的应用

用于 HAR 的可穿戴传感器如图 2 所示，主要包括脑电波（EEG）传感器、肌电图（EMG）、近红外光谱（NIR）等。这些传感器可放置在人体的不同部位，以获取最精准的人体活动特征信息，具体分析如下。




图 2 用于 HAR 的可穿戴传感器

2.1 单体可穿戴传感器

2.1.1 脑电波传感器

脑电波（EEG）传感器通过额头电极和耳夹电极采集数据，通过差分放大、滤波、数模转换等步骤将电信号变成传感器数据^[12]。EEG 能够反映个体的情绪、注意力和疲劳等状态，脑机接口可以将 EEG 转化为指令，控制计算机、轮椅、假肢等外部设备，实现非言语沟通或活动控制。因此，EEG 传感器可以识别特定场合下的人体活动状态，相较其他传感器，EEG 传感器能够更准确地反映个体活动状态和疲劳程度^[13]。但 EEG 传感器需要多个电极加持，同时需要导电凝胶配合使用，且汗液会对微弱信号产生不利影响，因此需要进一步提升 EEG 传感器性能^[14]。

2.1.2 惯性测量单元传感器

惯性测量单元（IMU）传感器是一种集成了加速度计、陀螺仪及磁力计的 MEMS 系统^[15]。具体而言，加速度计用于测量三个轴向（ x 、 y 和 z 轴）的加速度，检测线性活动和重力效应；陀螺仪用于测量旋转活动速度，即滚动、偏航和俯仰；磁力计用于探测并测量磁场，用以纠正航向角。

IMU 传感器数据能够还原任何时间的载体姿态，同理也能够还原人体活动，但需要更复杂的计算和更大的累计误差^[16]。相较而言，HAR 作为一个分类任务，通过对人体不同位置的 IMU 传感器直接提取到的活动特征信息进行模式识别，实现不同活动的分类。在动作复杂的情况下，需要增加 IMU 传感器个数和优化人体佩戴方式。

2.1.3 心电图

心电图（ECG）是较为常用的心率监测传感技术^[17]。ECG 通过贴附于身体表面的电极捕捉心脏的电生理活动。鉴于 ECG 能够直接测量心脏活动的电信号，通常能够提供更为精确的心率数据，因此常被用于评估光电容积描记法（PPG）^[18-19]的准确性。

2.1.4 生物传感器

(1) 肌电图（EMG）。用于测量肌肉活动和收缩过程中产生的电活动，能够评估和诊断肌肉及活动神经元的功能状态。EMG 可用于识别上肢活动，包括由手/腕活动引起的收缩、拉伸和扭转^[20]。EMG 分为表面 EMG（sEMG）和肌内 EMG（iEMG）。其中，sEMG 通过置于皮肤上的电极阵列捕捉肌肉产生的电信号，但易受干扰，如电极移位、肢体位置、肌肉收缩强度、概念漂移等，进而影响对手势的分类和回归^[21]。

(2) 力肌电图（FMG）。利用力感应元件测量皮肤表面的压力分布曲线。这些压力曲线随收缩量的变化而变化^[22-23]。基于 FMG 的识别技术具有更高的离线分类精度，可作为替代 EMG 的有效方法。

(3) 肌音信号（MMG）。采用麦克风或加速度计测量低频肌肉收缩和振动。例如，大腿多通道 MMG 信号能够用于检测膝关节活动，从而有

助于开发下肢假肢的电动辅助可穿戴传感器。Castillo 等^[24]对手臂活动的预测准确率最高达 97%，对不同模态的识别准确率达 86.7% ~ 93.3%。(力)肌电图示意图^[25]如图 3 所示。




图3 (力)肌电图示意图

2.1.5 柔性压力传感器

在人体活动中，跌倒和神经疾病引起的步态缺陷检测是亟待解决的重要问题^[25]。此外，脑瘫、中风后痴呆、髌股关节疼痛综合征、膝骨关节炎及肌腱破裂等疾病均可能导致步态冻结和活动缺陷^[26-27]，因此，亟须研究更加有效的监测方法。柔性压力传感器可检测步态缺陷关键信息，相关产品有压力感知鞋垫等。适用于手、足的柔性压力传感器^[28]如图 4 所示。




图4 适用于手、足的柔性压力传感器

2.2 多传感器融合系统

多传感器融合系统在 HAR 中具有重要作用。通过整合来自不同传感器的数据，提高 HAR 识别的准确性和可靠性。该系统既包括可视化数据流与非可视化数据流的融合，也包括非可视化数据之间的融合^[27]。

2.2.1 sEMG-IMU 融合系统

对于区分度较低的活动或面向局部（如手

部、腿部）较为精细的动作时，单一 IMU 传感器无法完成任务。sEMG 与目标肌肉的神经驱动强度间存在高度相关性，但仅利用 sEMG 信号无法满足多功能 HAR 的实际应用需要。主要原因包括：①存在活动伪影，包括电极和皮肤之间的界面伪影，以及连接电极和放大器的电缆伪影，导致传感器数据和模式结果不一致；②存在大量的自由度和上肢的非循环性质的动作。

综上所述，sEMG-IMU 融合系统^[28]能够提高人体活动识别精度，但存在传输延迟和对齐、以停顿划分动作的共性问题。

2.2.2 sEMG-FMG 融合系统

表面肌电图-功能性肌电图传感臂带的通用接触点配置通常是异位的，因为相较共位配置，其实施过程更为简便。而共位配置的优势在于能够通过提供来自同一身体部位的不同传感器的补充信息，实现更为精确的手部运动分类。研究表明，sEMG-FMG 融合系统的跨模态学习能够提高动作识别精度，用于手势识别的单一 EMG 准确率为 81.5%，单一 FMG 为 80.6%，而 sEMG-FMG 准确率最高，为 91.6%^[29]。

此外，研究人员将 EMG、FMG、MMG、PPG、IMU 和 NIRS 相结合用于 HAR^[30]。研究发现，相较单一模态，多传感器融合系统识别精度更高，能够提升人体活动的识别精度。Xia 等^[31]指出，基于 SMG 传感器的便携式混合系统有助于提高手部活动识别的准确性，与单独使用某一特征传感器相比，准确率提高了 20.6%。

综上所述，多传感器融合系统能够提供多维度模态信息，从而提高 HAR 的精度。但多传感器融合系统也面临着诸多挑战，包括如何实现低功耗和低延迟、解决在线检测时的传输延迟和对齐问题以及模型优化等^[32]。

3 HAR 数据集

3.1 基于惯性的 HAR 数据集

基于惯性的 HAR 数据集见表 1。各数据集

的差异性体现在活动内容、主题类别、采样频率等方面。OPPORTUNITY数据集^[33]主要针对HAR交互场景,包括人体活动和场景反馈传感器。其中,用于HAR的可穿戴传感器包括7个9D IMU传感器,以及若干个3D加速度计和环境传感器。目前,基于惯性的HAR数据集体量较小,传感器的放置部位、采集精度和采集标准难以统一,需要借助迁移学习等算法解决数据集间的差异性问题。

3.2 基于生物传感器的HAR数据集

基于生物传感器的HAR数据集侧重于局部动作识别,如手部、足部及肌肉组织。因此,在基于生物传感器的HAR数据集中往往包含疾病信息数据。由于应用场景的特殊性,该类数据集体量较小,大多仅覆盖研究领域内样本特性。因此,如何提升相关算法的迁移性和鲁棒性尤为重要。基于sEMG的HAR数据集见表2。

表1 基于惯性的HAR数据集

数据集	活动内容	主题类别(个)	采样频率/Hz	活动类别(个)	样本数(个)	传感器类别
OPPORTUNITY ^[33]	日常活动	4	32	16	701 366	A、G、M、O、AM
Skoda Mini Checkpoint ^[34]	工厂活动	1	96	10	22 000	A
UCI Smartphone ^[35]	日常活动	30	50	6	10 299	A、G
PAMAP2 ^[36]	日常活动	9	100	18	2 844 868	A、G、M
USC-had ^[37]	日常活动	14	100	12	2 520 000	A、G
WISDM ^[38]	日常活动	29	20	6	1 098 207	A
DSADS ^[39]	日常活动	8	25	19	1 140 000	A、G、M
Darmstadt Daily Routines ^[40]	日常活动	1	100	35	24 000	A
Actitracker ^[41]	日常活动	36	20	6	2 980 765	A
SHO ^[42]	日常活动	10	50	7	630 000	A、G、M
mhealth ^[43]	日常活动	10	50	12	16 740	A、C、G
Daphnet Gait dataset ^[44]	步态	10	64	2	1 917 887	A
ActiveMiles ^[45]	日常活动	10	50~200	7	4 390 726	A
HASC ^[46]	日常活动	5	10~100	6	—	A、G、M、GPS
ActRectut ^[47]	姿势	2	32 Hz	12	102 613	A、G
UCI HAR ^[36]	日常活动	30	50 Hz	6	10 299	A、G
The OU-ISIR Gait Database ^[48]	步态	460	100Hz	5	—	A、G

注: A表示加速度计, G表示陀螺仪, M表示磁力计, AM表示环境传感器, O表示接近距离传感器, GPS表示全球定位系统。

表2 基于sEMG的HAR数据集

数据集	描述	活动类别(个)	总试验次数	传感器位置	采样频率/Hz	数据集	描述	活动类别(个)	总试验次数	传感器位置	采样频率/Hz
Ninapro 1 ^[49]	27S (20M7F)	52	14 040	手、手指	100	Sapsanis 2 ^[55]	1S	100	1800	手	4000
Ninapro 4 ^[50]	10S (6M4F)	52	3120	—	2000	Al-Timemy ^[56]	9A (7M2F)	6	1077	手	2000
Ninapro 7 ^[51]	22 (20S2A)	40	5280	—	2000	Theo ^[57]	4S (3M1F)	20	100	上臂、大腿	1000
Khushaba 1 ^[52]	8S (6M2F)	10	480	手指	4000	BASAN	22S	3	132	上肢	1000
Khushaba 4 ^[53]	11S (9M2F)	7	2310	上肢	4000	HAR-sEMG ^[58]	9S (7M2F)	5	3600	上肢	2000
Sapsanis 1 ^[54]	5S (2M3F)	6	900	手	500						

注: S表示声音, A表示截肢者, M表示男性, F表示女性。

4 智能算法

4.1 机器学习算法

机器学习算法依赖手工特征提取，首先对传感器采集的数据进行预处理和特征提取，再利用有监督或无监督的机器学习算法实现分类。

4.1.1 数据预处理

考虑到可穿戴传感器的原始采集数据包含噪声特征，导致分类效果不佳。因此，需要在算法识别之前消除噪声和冗余信号。FMG 和 IMU 传感器的信噪比 (SNR) 在可接受范围内，一般无需滤波，但通常需要纳入校准传感器参数。sEMG 传感器数据的预处理包括偏移补偿、平滑、整流

和放大等步骤，并利用中值滤波、高斯滤波、卡尔曼滤波和小波阈值等方法去噪。

4.1.2 特征提取

特征提取是 HAR 应用的关键步骤之一，其识别准确率在很大程度上取决于从原始信号中提取的特征。在机器学习算法中，可以从时域 (TD)、频域 (FD) 或时频域 (TFD) 中提取来自数字信号的手工特征。其中，TD 特征包括从信号中提取的有意义信息，FD 特征包括频率比 (FR)、SNR 和谱动量 (SM)^[59]。相较而言，TFD 特征包括信号幅度和 PSD 信号。此外，时间相关功率谱描述符 (TD-PSD) 和时间-空间描述符 (TSD) 也可作为有效特征^[60]。一个特征仅提供有限的信息，因此需要组合来自不同组的多个特征。特征提取统计指标见表 3。

表 3 特征提取统计指标

特征名称	特征公式	特征名称	特征公式
均值	$\bar{x} = \frac{1}{N} \sum_{i=1}^n x_i$	偏度	$S = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^3}{\sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}}$
中值	$Q_{\frac{1}{2}}(x) = \begin{cases} x'_{\frac{n+1}{2}}, & \text{if } n \text{ is odd number.} \\ \frac{1}{2}(x'_{\frac{n}{2}} + x'_{\frac{n}{2}+1}), & \text{if } n \text{ is even number.} \end{cases}$	峰度	$K = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^4}{\sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}} - 3$
均方根	$\sqrt{\frac{\sum_{i=1}^n x_i^2}{n}}$	谱能量	$P = \frac{1}{N} \sum_{n=0}^{N-1} x(n) ^2$
四分位数	$Q_1 = x(n+1)/4$ $Q_2 = x(n+1)/2$ $Q_3 = 3x(n+1)/4$	标准差	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^n (x_i - \bar{x})^2}$
轴间相关系数	$r(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X)var(Y)}}$	中值绝对偏差	$MAD = \text{median}(X_i - \bar{X})$
皮尔逊相关系数	$\rho_{X, Y} = \frac{cov(X, Y)}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y}$	样本熵	$Ent(X) = \sum_i P(x_i) \ln(x_i)$ $= - \sum_i P(x_i) \log_b P(x_i)$
小波变换	$X(a, b) = \frac{1}{\sqrt{b}} \int_{-\infty}^{\infty} x(t) \Psi\left(\frac{t-a}{b}\right) dt$	自回归系数	$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t$
过零率	$ZCR = \frac{1}{2} \sum_{m=1}^N \text{sgn}[x(m)] - \text{sgn}[x(m-1)] $		

4.1.3 机器学习算法

机器学习算法通常包括基于分类的有监督学习和基于聚类的无监督学习^[61]，具体见表4。其中，有监督学习是一种任务驱动方法。通过创建数学模型将输入映射到所需的输出，并尽可能准确地将数据分配至一个簇。其主要目标是将风险或错误降至最低。无监督学习无需数据标签，只需查找给定数据点集之间的相似性。根据相似性指标进行聚类划分，目标是最小化集群内距离和最大化集群间距离，从而达到分类目的^[62]。

4.2 深度学习算法

深度学习算法是机器学习算法的分支，其优势主要体现在两个方面：一方面，深度学习算法不需要手动选择特征，可以通过学习过程从原始数据中自动学习分层；另一方面，受数据增加、

硬件加速和算法优化等因素影响，面对丰富的数据样本往往需要强大而复杂的模型，而GPU和FPGA的发展极大缩短了模型训练时间。与机器学习算法相比，深度学习算法在基于可穿戴传感器的人体活动识别中表现出更强的优势，主要包括：①具有更高的准确性和鲁棒性；②无须手动提取和选择，能够自动学习更深层次的特征；③能够提取混合模态任务的跨模态特征。该算法可以从原始数据中学习，无须提取手工特征，减少了数据预处理步骤。

深度学习算法主要包括自动编码器（Autoencoder）、深度置信网络（DBN）、卷积神经网络（CNN）、循环神经网络（RNN）、深度强化学习（DRL）、生成对抗网络（GAN）、长短时记忆模型（LSTM）及其混合模型等^[63]。常用的深度学习算法见表5。其中，ANN算法结构简单，适用

表4 常用的机器学习算法

类别	算法	描述	优势	劣势
有监督学习	K近邻算法（KNN）	使用欧氏距离等度量方式计算当前活动与已有活动的相似性，适合小数据集	实现简单，不需要训练	在大规模数据中效率较低
	支持向量机（SVM）	划分不同活动类别的最优决策边界，使用线性或非线性的核函数进行分类	对高维数据和小样本集的效果好	计算复杂，参数选择敏感
	决策树（Decision Tree）	树状结构，利用传感器特征值递归划分数据，叶节点对应不同的活动类别	易于理解和解释	容易过拟合，特别是对于高噪声数据
	随机森林（Random Forest）	集成多个决策树，对各决策树的分类结果进行投票，选择票数最多的类别	具有较强的鲁棒性和较高的分类准确性	计算复杂性较高
	朴素贝叶斯分类器	基于贝叶斯定理，假设传感器特征是相互独立的	快速高效，适用于实时 HAR	独立性假设在实际应用中可能不完全成立
	线性判别分析	通过将数据投影到低维空间以最大化类间方差与类内方差的比值，用于分类活动	适合线性可分的数据	对非线性数据的效果不佳
无监督学习	K均值（K-means）	属于迭代聚类算法，目的是将数据分为K个簇，每个簇内的样本尽可能相似，而不同簇之间的样本尽可能不同	简单高效，适合大规模数据	需要预设K值，易陷入局部最优，不能处理复杂簇结构
	层次聚类	构建具有层次结构的聚类树（树状图）表示数据的聚类过程	无须预定义簇的数目K和生成树状结构量	计算复杂度高，受噪声影响大
	密度聚类算法（DBSCAN）	能够识别任意形状的簇且能处理噪声	适合任意形状的簇，处理噪声效果好	对参数敏感，处理密度变化大的数据效果较差

表5 常用的深度学习算法

算法	描述	优点	缺点
人工神经网络 (ANN)	属于基本的神经网络结构,模仿生物神经元,由输入层、隐藏层和输出层组成	简单易用	不适合高维数据,对过拟合敏感
卷积神经网络 (CNN)	通过卷积核捕捉图像的局部特征,擅长处理图像和其他二维数据	能够减少参数数量,提升效率	需要大量数据,计算复杂度较高
循环神经网络 (RNN)	通过循环连接处理时间序列数据,擅长记忆序列中的历史信息	能够处理时间序列数据,捕捉时间依赖	梯度消失问题,训练复杂度高
长短期记忆网络 (LSTM)	解决了长时依赖问题,适合处理长序列的数据	能够捕捉长时依赖信息,解决了梯度消失问题	训练复杂且计算量大
自编码器 (AE)	通过编码-解码结构对输入数据进行降维或特征提取	无须标注数据,能够降维	生成效果有限,重建质量不高
变分自编码器 (VAE)	自编码器的生成模型,能够生成具有一定分布规律的新数据	能够生成新数据,具有连续潜在空间	生成质量较低,难以捕捉复杂模式
生成对抗网络 (GAN)	由生成器和判别器组成,生成器生成数据,判别器判断数据真假	生成数据效果好,灵活性强	训练不稳定,容易出现模式崩溃
Transformer	基于注意力机制的模型,擅长处理序列数据	能够捕捉长程依赖,支持并行处理,适合长序列	计算复杂度高,数据需求大

于小规模数据集^[64]; CNN 算法更擅长处理图像数据,能够提取相邻像素之间的特征变化,但针对可穿戴传感器采集的数据,该算法精度难以保证,同时该算法计算包含卷积,在处理时间序列数据时计算复杂度较高,且对时序不敏感^[65]; RNN 和 LSTM 算法对连续动态活动的识别效果较好,如动态姿态转换^[66]; Transformer 算法在处理时间序列和复杂 HAR 任务时优势突出,但计算量较大,更适合数据充足且计算资源丰富的场景^[67]。

4.3 多模态算法

为了识别复杂性更高的人体活动,多模态算法成为发展趋势。多模态算法易受传感器故障、空间覆盖有限、精度较低等因素制约,解决方案通常基于多异构或同质传感器融合的鲁棒感测系统,即将不同的感测模态与数据融合技术相结合,以弥补其他模态的缺点,并为 HAR 提供完整的信息。

针对抽象的数据处理,可以在数据级、特征

级、决策级等方面进行融合^[68]。其中,数据级融合也称为早期融合。在机器学习算法输入之前,将多个同源的原始数据或预处理后的数据组合成特征向量。然而,数据级融合的缺点是不同数据源之间的时间同步性。为此,研究人员提出将卷积、训练和池化相融合,或者将离散时间序列与连续时间序列相集成。特征级融合是指从多个数据源中提取特征以创建新的高维特征向量。然而,为了找到最重要的特征子集,通常需要构建大型训练集。例如,利用特征级融合进行 150 个子词的中文手语识别,选择 sEMG、加速度和陀螺仪传感器用于实验信号采集,识别准确率为 95.1%^[69]。决策级融合是指从不同来源的单独决策中生成一系列假设,并从中选择一个概率最高的假设^[70]。

5 发展趋势分析

5.1 新型传感器

近年来,可穿戴传感器发展迅速,柔性压阻

阵列、汗液传感器、柔性接触传感器、光学传感器等相关研究成效显著,有望为 HAR 提供更多的信息数据。Liu 等^[71]研发的由眼内压应变传感器、 Ti_3C_2Tx 温度传感器和 IOP 护理点监测构成的神经假体隐形眼镜,能够通过监测眼压实现眼睛疲劳程度检测。研究表明,当眼压偏离正常范围时,活体大鼠的腿部抽搐能够通过体感皮层控制的运动皮层控制,实现生物感觉运动回路模拟,预示着借助眼压信号监测人体活动成为可能。Tehrani 等^[72]提出了一种灵活、可拉伸的可穿戴多传感器柔性贴片,如图 5 所示。利用小型超声换能器组成血压传感器,通过导电油墨焊接至贴片上;化学传感器则采用电极和药物诱导原理实现。该传感器贴片能够检测血压与汗液中的成分。尽管目前传感器仍需要通过有线方式传输数据,但前端柔性多传感器系统验证了多模态、柔性可穿戴传感器的可行性,为未来研究奠定了理论基础。




图 5 可穿戴多传感器柔性贴片

5.2 感存算一体架构

为突破冯诺依曼式计算架构的瓶颈,解决存储与计算单元分离的物理结构限制其计算效率的问题,感知-存储-计算一体架构被提出,用以减少模块间信息传输、模数转换带来的延迟与能耗,提升加工兼容性与集成度。受大脑功能的启发,神经形态计算实现了处理器与内存的无缝集成以及传感单元与神经网络芯片的融合。非易失性忆阻器因其快速访问、超低功耗、高密度、高耐用性及与 CMOS 工艺的兼容性等优势,被用于模拟人工神经元和突触,实现了计算模式上的重大革新。这种计算模式不仅模仿了神经系统的结构和功能,而且提升了数据处理的速度和效率,为人

工智能、机器学习及边缘计算等领域的发展开辟了新的方向^[73]。

5.2.1 近传感器(内)计算

近传感器(内)计算是指将部分计算单元集成至传感单元,过滤冗余数据并提取传感器输出的有效数据,降低传输延迟和功耗^[74]。与传统的传感器-模数转换器(ADC)-内存-后端架构相比,该架构中传感和计算单元的 ADC 和内存被神经形态设备所取代。传感器(内)计算系统多功能传感单元的设计既能实现环境信号输入,又能执行简单计算,消除了冗余数据传输产生的消耗。Liu 等^[75]和 Jiang 等^[76]设计的近传感器触觉系统以神经形态晶体管代替硬件电路,显著提高了可穿戴传感器的性能。该方法使得传感器和神经形态器件的设计变得更加自由,但需要更多的能源消耗且耐磨性较差。与硬件电路相比,在制备神经形态晶体管时,使用有机材料与近传感器感知系统能够有效提升兼容性。Sengupta 等^[77]设计了一种柔性且可拉伸的电纺碳纳米纤维(CNF)传感器,能够响应 $0^\circ \sim 90^\circ$ 的角度弯曲。该传感器阵列也可用于手势检测和识别。

5.2.2 存算一体架构

存算一体架构针对传感器输出数据进行直接处理,以快速、高度并行和节能的方式执行近似矩阵向量乘法计算^[78]。Huang 等^[79]设计了一种使用忆阻电路的多模态神经形态感觉处理系统,可以实现相对较高准确率(约 90.37%)的室内人体活动识别;Ning 等^[80]使用双相二维材料构建了内存计算系统,在非线性定位任务中的识别准确率为 99.86%。虽然存算一体架构性能优越,但一方面由于复杂的工艺性,存算一体架构硬件尚未普及;另一方面,由忆阻器等器件构建的网络模型需要进一步优化,包括器件精度对模型的干扰和调控等。

5.3 多模态算法

(1) 跨模态对齐。当前,多模态算法无法充分利用数据特征。未来,将着重于更精细的跨模态对齐,使来自不同模态的数据在特征层面实现

更好地协同。例如,结合传感器数据、语音、图像等信息时,通过引入跨模态注意力机制自动选择和对齐不同模态中最相关的信息^[81]。此外,深度学习算法中的变分自编码器和生成对抗网络也可以用于跨模态融合,以提升整体识别效果。

(2) 提高鲁棒性。未来,多模态算法需要具备更强的模态缺失处理能力,实现对现有模态的推断、补全等。例如,通过知识蒸馏或多模态生成模型补全缺失的模态数据,提升系统的鲁棒性和准确性。

(3) 提升轻量化与实时性。感存算一体化是未来的发展趋势,轻量化的推理模型能够降低功耗、减少延迟,进而推动基于智能感知的 HAR 技术的发展^[82]。

6 结语

本文从智能传感技术、数据集及智能算法等维度进行全面归纳梳理。目前,基于智能感知的 HAR 技术具有一定研究基础,从人体活动模型的构建到丰富的公开数据集都为相关研究提供了相对完备的数据资源,在此基础上衍生出了支持离线/在线检测的多种算法。随着新型柔性传感器和感存算一体架构的发展,基于智能感知的 HAR 技术能够进一步提升可穿戴传感器的便携性。

未来, HAR 技术应在以下方面开展深入研究:①进一步探索有监督学习与无监督学习算法,以减少对大规模标注数据的依赖;②优化多模态数据的对齐与融合方法,特别是在处理模态数据缺失和数据不对齐的问题时,现有算法的鲁棒性仍不足;③系统的实时性和轻量化是实际应用中的关键瓶颈,需要在资源受限的环境下实现高效计算;④提高算法的可解释性和个性化,使系统不仅能够提供准确的识别结果,而且能够清晰展示决策依据,并针对用户的个性差异进行自适应调整。

综上所述, HAR 技术能够在智能感知领域发挥更大的作用,为人们提供更加个性化和智能化的服务。

参考文献

- [1] SERPUSH F, MENHAJ M B, MASOUMI B, et al. Wearable sensor-based human activity recognition in the smart healthcare system [J]. *Computational Intelligence and Neuroscience*, 2022 (2): 1391906.
- [2] MEKRUKSAVANICH S, JITPATTANAKUL A. Biometric user identification based on human activity recognition using wearable sensors: an experiment using deep learning models [J]. *Electronics*, 2021, 10 (3): 308.
- [3] LIU R, RAMLI A A, ZHANG H, et al. An overview of human activity recognition using wearable sensors: healthcare and artificial intelligence [C]. 2021 International Conference on Internet of Things-ICIOT, 2021.
- [4] YADAV S K, TIWARI K, PANDEY H M, et al. A review of multimodal human activity recognition with special emphasis on classification, applications, challenges and future directions [J]. *Knowledge-Based Systems*, 2021 (223): 106970.
- [5] ISLAM M M, NOORUDDIN S, KARRAY F, et al. Human activity recognition using tools of convolutional neural networks: a state of the art review, data sets, challenges, and future prospects [J]. *Computers in Biology and Medicine*, 2022 (149): 106060.
- [6] SUN W B, GUO Z L, YANG Z Q, et al. A review of recent advances in vital signals monitoring of sports and health via flexible wearable sensors [J]. *Sensors*, 2022, 22 (20): 7784.
- [7] WAN T Q, SHAO B J, MA S J, et al. In-sensor computing: materials, devices, and integration technologies [J]. *Advanced Materials*, 2023, 35 (37): 2203830.
- [8] 吉司, 森塔戈泰. 人体解剖图谱: 骨骼, 关节, 韧带, 肌肉 [M]. 北京: 人民卫生出版社, 1959.
- [9] CHI H G, HA M H, CHI S, et al. InfoGCN: representation learning for human skeleton-based action recognition [C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022.
- [10] SCATAGLINI S, TRUIJEN S. Overview of software and file exchange formats in 3D and 4D body shape scanning [C]. Proceedings of the 7th International Digital Human Modeling Symposium (DHM 2022), 2022.
- [11] DANG L M, MIN K, WANG H X, et al. Sensor-based and vision-based human activity recognition: a comprehensive survey [J]. *Pattern Recognition*, 2020 (108): 107561.
- [12] BANIQUED P D E, STANYER E C, AWAIS M, et al. Brain-computer interface robotics for hand rehabilitation after stroke: a

- systematic review [J]. *Journal of Neuroengineering and Rehabilitation*, 2021 (18): 15.
- [13] TAO W, LI C, SONG R C, et al. EEG-based emotion recognition via channel-wise attention and self attention [J]. *IEEE Transactions on Affective Computing*, 2023, 14 (1): 382-393.
- [14] HE C Y, CHEN Y Y, PHANG C R, et al. Diversity and suitability of the state-of-the-art wearable and wireless EEG systems review [J]. *IEEE Journal of Biomedical and Health Informatics*, 2023, 27 (8): 3830-3843.
- [15] AHMAD N, GHAZILLA R A R, KHAIRI N M, et al. Reviews on various inertial measurement unit (IMU) sensor applications [J]. *International Journal of Signal Processing Systems*, 2013, 1 (2): 256-262.
- [16] 秦永元. 惯性导航 [M]. 2版. 北京: 科学出版社, 2014.
- [17] PANKAJ, KUMAR A, KOMARAGIRI R, et al. A review on computation methods used in photoplethysmography signal analysis for heart rate estimation [J]. *Archives of Computational Methods in Engineering*, 2022 (29): 921-940.
- [18] EL_RAHMAN S A. Biometric human recognition system based on ECG [J]. *Multimedia Tools and Applications*, 2019 (78): 17555-17572.
- [19] ALMANIFI O R A, KHAIRUDDIN I M, RAZMAN M A M, et al. Human activity recognition based on wrist PPG via the ensemble method [J]. *ICT Express*, 2022, 8 (4): 513-517.
- [20] RANI G J, HASHMI M F, GUPTA A. Surface electromyography and artificial intelligence for human activity recognition: a systematic review on methods, emerging trends applications, challenges, and future implementation [J]. *IEEE Access*, 2023 (11): 105140-105169.
- [21] IBRAHIM A F T, GANNAPATHY V R, CHONG L W, et al. Analysis of electromyography (EMG) signal for human arm muscle: a review [C]. *Advanced Computer and Communication Engineering Technology: Proceedings of ICOCOE 2015*, 2015.
- [22] ISLAM M R U, WARIS A, KAMAVUAKO E N, et al. A comparative study of motion detection with FMG and sEMG methods for assistive applications [J]. *Journal of Rehabilitation and Assistive Technologies Engineering*, 2020 (7): 2055668320938588.
- [23] WANG C J, CAI M, HAO Z M, et al. Stretchable, multifunctional epidermal sensor patch for surface electromyography and strain measurements [J]. *Advanced Intelligent Systems*, 2021, 3 (11): 2100031.
- [24] CASTILLO C S M, WILSON S, VAIDYANATHAN R, et al. Wearable MMG-plus-one armband: evaluation of normal force on mechanomyography (MMG) to enhance human-machine interfacing [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021 (29): 196-205.
- [25] JAMES K, ELDEMIRE-SHEARER D, GOULDBOURNE J, et al. Falls and fall prevention in the elderly: the jamaican perspective [J]. *The West Indian Medical Journal*, 2007, 56 (6): 534-539.
- [26] PRAKASH C, KUMAR R, MITTAL N. Recent developments in human gait research: parameters, approaches, applications, machine learning techniques, datasets and challenges [J]. *Artificial Intelligence Review*, 2018 (49): 1-40.
- [27] NI J Y, TANG H, HAQUE S T, et al. A survey on multimodal wearable sensor-based human action recognition [J]. *arXiv*, 2024 (4): 2404.15349.
- [28] CHANG W N, DAI L L, SHENG S L, et al. A hierarchical hand motions recognition method based on IMU and sEMG sensors [C]. *2015 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, 2015.
- [29] JIANG S, GAO Q H, LIU H Y, et al. A novel, co-located EMG-FMG-sensing wearable armband for hand gesture recognition [J]. *Sensors and Actuators A: Physical*, 2020 (301): 111738.
- [30] WANG H, KANG P Q, GAO Q H, et al. A novel PPG-FMG-ACC wristband for hand gesture recognition [J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26 (10): 5097-5108.
- [31] XIA W, ZHOU Y, YANG X C, et al. Toward portable hybrid surface electromyography/a-mode ultrasound sensing for human-machine interface [J]. *IEEE Sensors Journal*, 2019, 19 (13): 5219-5228.
- [32] DIN I U, GUIZANI M, HASSAN S, et al. The internet of things: a review of enabled technologies and future challenges [J]. *IEEE Access*, 2019 (7): 7606-7640.
- [33] ROGGEN D, CALATRONI A, ROSSI M, et al. Collecting complex activity datasets in highly rich networked sensor environments [C]. *2010 Seventh International Conference on Networked Sensing Systems (INSS)*, 2010.
- [34] ZAPPI P, LOMBRISER C, STIEFMEIER T, et al. Activity recognition from on-body sensors: accuracy-power trade-off by dynamic sensor selection [C]. *Wireless Sensor Networks: 5th European Conference*, 2008.
- [35] ANGUIA D, GHIO A, ONETO L, et al. A public domain dataset for human activity recognition using smartphones [C]. *ESANN 2013 Proceedings*, 2013.
- [36] REISS A, STRICKER D. Introducing a new benchmarked dataset for activity monitoring [C]. *2012 16th International Symposium on Wearable Computers*, 2012.
- [37] ZHANG M, SAWCHUK A A. USC-HAD: a daily activity dataset for ubiquitous activity recognition using wearable sensors [C]. *Proceedings of the 2012 ACM Conference on Ubiquitous*

- Computing, 2012.
- [38] KWAPISZ J R, WEISS G M, MOORE S A. Activity recognition using cell phone accelerometers [J]. *ACM SIGKDD Explorations Newsletter*, 2011, 12 (2): 74-82.
- [39] BARSHAN B, YÜKSEK M C. Recognizing daily and sports activities in two open source machine learning environments using body-worn sensor units [J]. *The Computer Journal*, 2014, 57 (11): 1649-1667.
- [40] HUYNH T, FRITZ M, SCHIELE B. Discovery of activity patterns using topic models [C]. *Proceedings of the 10th International Conference on Ubiquitous Computing*, 2008.
- [41] WEISS G M, LOCKHART J W, PULICKAL T T, et al. Actitracker: a smartphone-based activity recognition system for improving health and well-being [C]. *2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, 2016.
- [42] SHOAIB M, BOSCH S, INCEL O D, et al. Fusion of smartphone motion sensors for physical activity recognition [J]. *Sensors*, 2014, 14 (6): 10146-10176.
- [43] BANOS O, GARCIA R, HOLGADO-TERRIZA J A, et al. mHealthDroid: a novel framework for agile development of mobile health applications [C]. *Ambient Assisted Living and Daily Activities (IWAAL 2014)*, 2014.
- [44] ROGGEN D, PLOTNIK M, HAUSDORFF J. *UCI Machine Learning Repository: daphnet freezing of gait [Z]*. 2010.
- [45] RAVI D, WONG C, LO B, et al. A deep learning approach to on-node sensor data analytics for mobile or wearable devices [J]. *IEEE Journal of Biomedical and Health Informatics*, 2017, 21 (1): 56-64.
- [46] KAWAGUCHI N, OGAWA N, IWASAKI Y, et al. HASC challenge: gathering large scale human activity corpus for the real-world activity understandings [C]. *Proceedings of the 2nd Augmented Human International Conference*, 2011.
- [47] BULLING A, BLANKE U, SCHIELE B. A tutorial on human activity recognition using body-worn inertial sensors [J]. *ACM Computing Surveys (CSUR)*, 2014, 46 (3): 1-33.
- [48] IWAMA H, OKUMURA M, MAKIHARA Y, et al. The OUISIR gait database comprising the large population dataset and performance evaluation of gait recognition [J]. *IEEE Transactions on Information Forensics and Security*, 2012, 7 (5): 1511-1521.
- [49] ZHANG Y, YANG F, FAN Q, et al. Research on sEMG-based gesture recognition by dual-view deep learning [J]. *IEEE Access*, 2022 (10): 32928-32937.
- [50] XU Z Y, YU J X, XIANG W T, et al. A novel SE-CNN attention architecture for sEMG-based hand gesture recognition [J]. *Computer Modeling in Engineering & Sciences*, 2023, 134 (1): 157-177.
- [51] DAI Q F, WONG Y K, KANKANHALI M, et al. Improved network and training scheme for cross-trial surface electromyography (sEMG) —based gesture recognition [J]. *Bioengineering*, 2023, 10 (9): 1101.
- [52] KHUSHABA R N, KODAGODA S. Electromyogram (EMG) feature reduction using mutual components analysis for multifunction prosthetic fingers control [C]. *2012 12th International Conference on Control Automation Robotics & Vision (ICARCV)*, 2012.
- [53] KHUSHABA R N, TAKRURI M, MIRO J V, et al. Towards limb position invariant myoelectric pattern recognition using time-dependent spectral features [J]. *Neural Networks*, 2014 (55): 42-58.
- [54] SAPSANIS C, GEORGOULAS G, TZES A, et al. Improving EMG based classification of basic hand movements using EMD [C]. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2013.
- [55] SAPSANIS C. Recognition of basic hand movements using electromyography [J]. *arXiv*, 2018 (10): 1810.10062.
- [56] AL-TIMEMY A H, KHUSHABA R N, BUGMANN G, et al. Improving the performance against force variation of EMG controlled multifunctional upper-limb prostheses for transradial amputees [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2016, 24 (6): 650-661.
- [57] THEODORIDIS T, AGAPITOS A, HU H S. A gaussian groundplan projection area model for evolving probabilistic classifiers [C]. *Proceedings of the 13th Annual Conference on Genetic and Evolutionary Computation*, 2011.
- [58] LUAN Y, SHI Y H, WU W Y, et al. HAR-sEMG: a dataset for human activity recognition on lower-limb sEMG [J]. *Knowledge and Information Systems*, 2021 (63): 2791-2814.
- [59] GU F Q, KHOSHELHAM K, VALAEE S, et al. Locomotion activity recognition using stacked denoising autoencoders [J]. *IEEE Internet of Things Journal*, 2018, 5 (3): 2085-2093.
- [60] KHUSHABA R N, AL-ANI A, AL-TIMEMY A, et al. A fusion of time-domain descriptors for improved myoelectric hand control [C]. *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2016.
- [61] AZEVEDO B F, ROCHA A M A C, PEREIRA A I. Hybrid approaches to optimization and machine learning methods: a systematic literature review [J]. *Machine Learning*, 2024 (113): 4055-4097.
- [62] NASTESKI V. An overview of the supervised machine learning methods [J]. *Horizons*, 2017 (4): 51-62.
- [63] ZHANG S B, LI Y X, ZHANG S, et al. Deep learning in human activity recognition with wearable sensors: a review on advances

- [J]. *Sensors*, 2022, 22 (4): 1476.
- [64] ZHANG C, YANG Z C, HE X D, et al. Multimodal intelligence: representation learning, information fusion, and applications [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2020, 14 (3): 478-493.
- [65] WANG B Y. Data feature extraction method of wearable sensor based on convolutional neural network [J]. *Journal of Healthcare Engineering*, 2022 (1): 1580134.
- [66] JAMEER S, SYED H. A DCNN-LSTM based human activity recognition by mobile and wearable sensor networks [J]. *Alexandria Engineering Journal*, 2023 (80): 542-552.
- [67] SUH S, REY V F, LUKOWICZ P. TASKED: transformer-based adversarial learning for human activity recognition using wearable sensors via self-knowledge distillation [J]. *Knowledge-Based Systems*, 2023 (260): 110143.
- [68] LAHAT D, ADALI T, JUTTEN C. Multimodal data fusion: an overview of methods, challenges, and prospects [J]. *Proceedings of the IEEE*, 2015, 103 (9): 1449-1477.
- [69] YU Y, CHEN X, CAO S, et al. Exploration of Chinese sign language recognition using wearable sensors based on deep belief net [J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24 (5): 1310-1320.
- [70] HASSANI S, DACKERMANN U, MOUSAVI M, et al. A systematic review of data fusion techniques for optimized structural health monitoring [J]. *Information Fusion*, 2024 (103): 102136.
- [71] LIU W J, DU Z J, DUAN Z Y, et al. Neuroprosthetic contact lens enabled sensorimotor system for point-of-care monitoring and feedback of intraocular pressure [J]. *Nature Communications*, 2024 (15): 5635.
- [72] TEHRANI F, TEYMOURIAN H, WUERSTLE B, et al. An integrated wearable microneedle array for the continuous monitoring of multiple biomarkers in interstitial fluid [J]. *Nature Biomedical Engineering*, 2022 (6): 1214-1224.
- [73] MIRANDA E, SUÑÉ J. Memristors for neuromorphic circuits and artificial intelligence applications [J]. *Materials*, 2020, 13 (4): 938.
- [74] LIU J L, WANG Y T, LIU Y W, et al. Recent progress in wearable near-sensor and in-sensor intelligent perception systems [J]. *Sensors*, 2024, 24 (7): 2180.
- [75] LIU X R, SUN C, GUO Z C, et al. Near-sensor reservoir computing for gait recognition via a multi-gate electrolyte-gated transistor [J]. *Advanced Science*, 2023, 10 (15): 2300471.
- [76] JIANG C P, LIU J Q, YANG L, et al. A flexible artificial sensory nerve enabled by nanoparticle-assembled synaptic devices for neuromorphic tactile recognition [J]. *Advanced Science*, 2022, 9 (24): 2106124.
- [77] SENGUPTA D, MASTELLA M, CHICCA E, et al. Skin-inspired flexible and stretchable electrospun carbon nanofiber sensors for neuromorphic sensing [J]. *ACS Applied Electronic Materials*, 2022, 4 (1): 308-315.
- [78] GHOSH A, SADANA H R, DEBNATH M, et al. Approximate ADCs for in-memory computing [J]. *arXiv*, 2024 (8): 2408.06390.
- [79] HUANG X H, LIU C S, TANG Z W, et al. An ultrafast bipolar flash memory for self-activated in-memory computing [J]. *Nature Nanotechnology*, 2023 (18): 486-492.
- [80] NING H K, YU Z H, ZHANG Q T, et al. An in-memory computing architecture based on a duplex two-dimensional material structure for in situ machine learning [J]. *Nature Nanotechnology*, 2023 (18): 493-500.
- [81] Peng Y X, Qi J W, Yuan Y X. Modality-specific cross-modal similarity measurement with recurrent attention network [J]. *IEEE Transactions on Image Processing*, 2018, 27 (11): 5585-5599.
- [82] Chang Z Q, Liu S B, Xiong X X, et al. A survey of recent advances in edge-computing-powered artificial intelligence of things [J]. *IEEE Internet of Things Journal*, 2021, 8 (18): 13849-13875. **IPE**

收稿日期: 2024-08-21

作者简介:

周凯月 (1992—), 女, 博士, 中国科学院微电子研究所博士后、助理研究员, 研究方向: 多模态人体活动识别、MEMS 传感器相关的片上可测试性设计及相关算法。

李佳 (通信作者) (1982—), 女, 博士, 研究员, 中国科学院微电子研究所智能感知芯片与系统研发中心副主任, 研究方向: 智能集成 MEMS 传感器系统和物联网系统应用。