arXiv:2301.06249v1 [cs.HC] 16 Jan 2023

DisPad：通过灵活调整织物传感器的身体佩戴位置偏移，实现稳健的关节运动跟踪

陈晓伟，厦门大学，中国蒋晓，厦门大学，中国方佳伟，厦门大学，中国郭世辉*，厦门大学，中国林俊聪，厦门大学，中国廖明宏，厦门大学，中国罗国良，华东交通大学，中国傅宏波，香港城市大学，中国

过去几十年来，可穿戴软传感器日益兴起；然而，软传感器在信号处理方面仍面临诸多重要挑战，限制了其实际应用。传感器发生位移时容易产生误差，导致其输出与理想值出现显著偏差。在这项工作中，我们提出了一种新型原型，将肘垫与稀疏的柔性传感器网络相结合。该原型完全生物相容、可拉伸且可穿戴。我们开发了一种基于学习的方法来预测肘部方向角，在单用户多运动实验中实现了 9.82 度的平均跟踪误差。通过迁移学习，我们的方法在不同运动类型和不同用户上的平均跟踪误差分别为 10.98 度和 11.81 度。我们的核心贡献在于提出了一种解决方案，可在不同设备位移情况下实现稳健、稳定的人体关节运动追踪。

CCS 概念：• **以人为中心的计算** → **普适与移动计算系统及工具**；**环境智能** **i-化** ·

附加关键词与短语：柔性传感器、纺织传感器、动作追踪、鲁棒信号处理、长短期记忆、迁移学习、领域自适应、模糊熵

1 引言

人体动作追踪不仅因其在理解人类意图方面的巨大潜力而受到广泛研究， [31], 还可用于主动控制物理设备和系统， [7, 44, 45]作为一种新型的人机交互方式，人体动作追踪可应用于多个领域，包括机器人学、触觉技术、生物力学研究、康复、医疗保健和娱乐。 [10, 11]电影、动画和游戏产业广泛使用的人体动作追踪解决方案基于光学追踪 [30] 或惯性传感器 [36]。一些研究还提出了结合这两类传感器的解决方案 [1]。这些解决方案在专业应用中取得了巨大成功，但对于优先考虑舒适性的消费级应用而言，可能并不理想，

*通讯作者：guoshihui@xmu.edu.cn。

作者地址：陈晓伟，wdenxwa@stu.xmu.edu.cn，厦门大学，中国福建省厦门市思明南路422号，邮编361005；蒋晓，24320182203214@stu.xmu.edu.cn，厦门大学，中国福建省厦门市思明南路422号，邮编361005；方佳伟，22920202204553@ stu.xmu.edu.cn，厦门大学，中国福建省厦门市思明南路422号，邮编361005；郭世辉，guoshihui@xmu.edu.cn，厦门大学，中国福建省厦门市思明南路422号，邮编361005；林俊聪，jclin@xmu.edu.cn，厦门大学，中国福建省厦门市思明南路422号，邮编361005；廖明宏，liao@xmu.edu.cn，厦门大学，中国福建省厦门市思明南路422号，邮编361005；罗国良，luoguoliang@ecjtu.edu.cn，华东交通大学，中国江西省南昌市双港东大街150号，邮编330013；傅宏波，hongbofu@cityu. edu.hk，香港城市大学，中国香港九龙塘达之路，邮编999077。

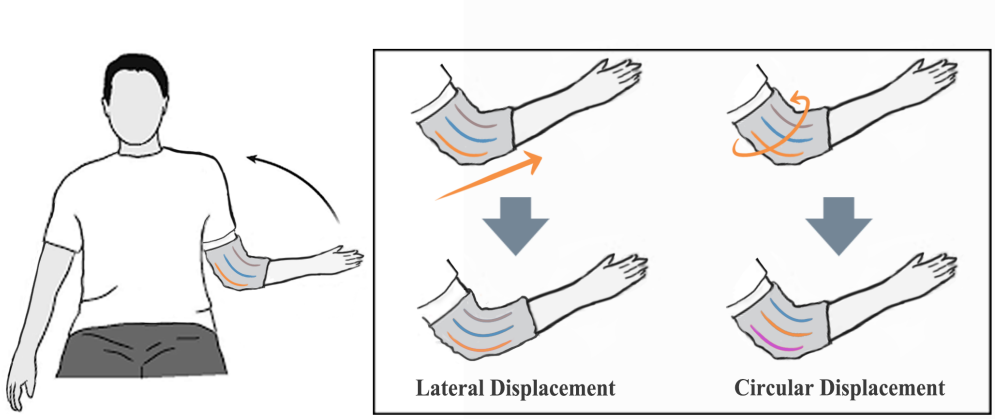

图 1. 我们的原 型 DisPad 即使在传感器发生横向和/或圆周位移的情况下，也能鲁棒地追踪人体关节方向。该
作以肘 部为例，展示我们的方法实现鲁棒关节追踪的功能。

用户体验的便利性。柔性传感器正逐渐成为监测人体活动的有前景的解决方案[42, 52]。它们具有生物相容性好、可拉伸性高、重量轻且易于集成到服装中的优势，能够长期监测人体生理状态。借助柔性传感器，动作捕捉不易受到上述因素的影响，例如光照条件、积分漂移和遮挡。因此，将柔性可穿戴传感器应用于人体动作捕捉、人机界面和软体机器人等领域的需求日益增长 [2]。

柔性传感器要充分发挥其在广泛人机交互（HCI）应用中的潜力，仍面临着严峻挑战。其中一个挑战是设备放置位置（下文称为 DisPad 位置），而且这一位置会因用户、运动类型和穿戴时段的不同而显著变化（图 1）。然而，现有方法要求具备专业知识，才能严格保持设备在受试者身上的位置 [35, 36, 47], ，从而降低了系统的鲁棒性和便利性。在某些特定场景（例如运动功能障碍的中风患者）中，无法严格满足固定位置这一要求。因此，基于设备放置位置固定这一假设的预测模型在实际使用场景中并不实用；当该假设不成立时，还可能产生严重的测量误差。

为应对这些挑战，我们提出了*DisPad*，即使设备放置位置存在较大变化，也能准确、稳健地追踪人体运动。作为概念验证，我们选择了肘关节，因为运动员常使用垫片，在摔倒或遭受撞击时保护自己免受伤害。我们相信，只要对设备和流程进行适当调整，我们基于学习的方法也能有效应用于其他关节。DisPad 基于一款标准纺织肘垫和由六个可拉伸传感器组成的稀疏网络。我们的方法不再严格要求设备必须准确放置在身体上，用户可以像穿戴普通垫片一样，以各种方式自由佩戴我们的原型。灵活的穿戴方式会显著影响原始传感器读数，并给传感器信号处理和任务相关算法带来巨大挑战。我们的核心贡献在于提出一种解决方案，能够在不同设备位移下实现低成本、稳健且稳定的人体关节运动追踪。为此，我们提出一种基于学习的算法，根据传感器读数预测矢状面上的关节角度

，并引入一种迁移学习技术，以进一步应对不同用户和运动类型所造成的变化。我们的方法让用户能够在几乎不受限制的情况下佩戴垫片，并确保系统具有最大的便利性。总而言之，我们的工作有三方面贡献。

- 一种基于学习的方法，用于处理传感器偏移所导致的传感器信号变化，实现灵活的身体佩戴设备放置位置。我们使用长短期记忆网络（LSTM）预测关节角度；在测试数据集中，当肘垫在同一用户手臂的一大片区域内随机放置时，平均误差为 9.82 度。

- 一种基于模糊熵和迁移学习的无监督方法，可使模型适应具有不同特征分布的数据集。该方法在不同运动类型中的平均误差为 10.98 度，在不同用户中的平均误差为 11.81 度。

- 一个系统原型，包含传感器信号采集、传输、角度预测和图形可视化，用于预测人体手臂关节角度。作为软硬件兼备的完整解决方案，该系统展现了灵活佩戴的柔性传感器用于稳健动作跟踪的潜力。

2 相关工作

2.1 人体动作捕捉

现有的人体动作捕捉方法包括基于视觉的方法 [8, 21, 31] 和非基于视觉的方法 [20, 33, 37]。基于视觉的方法使用 RGB、RGB-D 或红外摄像机捕捉图像并识别人体姿态。得益于深度学习近年来取得的成功，基于视觉的方法在理想条件下（光照充足且没有遮挡）实现了精确的身体跟踪。典型的非基于视觉的方法会将传感器（如惯性测量单元 [48]或超声波传感器 [12], ）附着于人体，以测量特定身体部位的方向和位置 [56]。由于惯性测量单元传感器成本低、体积小，基于惯性测量单元的追踪系统迄今仍是适用于不受限制的室内外环境的先进可穿戴解决方案 [48, 50]。为获得准确、稳定的追踪结果，研究人员开发了算法来处理积分运算造成的漂移问题 [16, 53, 54, 56]。例如，Yizhai等人采用基于扩展卡尔曼滤波器（EKF）的算法来校正漂移 [56]。现有的基于视觉和非基于视觉的解决方案已广泛应用于各种专业及消费领域。配备柔性传感器的可穿戴系统可补充现有方法，并拓展应用边界，适用于用户长时间佩戴时注重舒适性、且要求室内外使用都方便的场景。

研究人员已经探索了将柔性传感器用于动作追踪。迄今为止，现有方法已探索了追踪上半身 [15], 手指 [3, 10, 23, 39], 下肢 [20, 40],肘关节 [41], 和膝关节 [51]运动的应用。除了追踪关节角度，柔性传感器密集阵列还可用于测量局部区域变化，并重建复杂的皮肤变形 [22] 以及皮肤的微小拉伸（由动脉搏动引起） [24]。一些研究人员将柔性传感器与惯性传感器相结合，以实现关节动作追踪[55]。Yirmibesoglu等人开发了一种用于测量运动的混合柔性传感器 [55], ，该传感器由一种超弹性硅橡胶弹性体制成，其中嵌有填充导电液态金属的微通道。

该领域现有研究主要关注用于人体动作捕捉的传感器在准确度和实时性能方面的指标。近期一项研究在考虑较小范围的传感器位移（≤1 cm）的情况下，使用织物传感器跟踪关节角度 [38]。由于这项先前工作证实，传感器位移（即使在适中范围内）也会影响跟踪准确度，因此我们对这一尚待解决的问题进行了全面研究，并探索了在传感器位移较大的情况下实现准确跟踪的潜在解决方案。

2.2 稳健传感器布置

传感器位移问题是指传感器可能偏离理想配置，最终处于显著不同的位置配置。这一问题在使用可穿戴系统跟踪人体状态时经常出现，并给预训练的模式识别模型带来挑战。由于柔性传感器具有可变形的特性，在我们的应用中，这一问题尤为突出。

一种解决方案是分析位移数据，并使用算法对结果进行校正。一组研究人员假设，传感器位置和传感器特征分布的变化与协变量偏移一致 [49]。基于这一假设，他们提出了一种改进的交叉验证技术，称为材料加权交叉验证，可用于分类任务中的模型和参数选择。另一项研究结合陀螺仪和加速度计的信息，以区分旋转和平移 [35]。作者提出了一种启发式算法，用于计算变换矩阵并对人体运动进行分类。Foster等人提出了一种在线自校准方法，用于动态调整分类器模型 [19]。他们的方法在90度以内的圆周位移下表现出稳健性能，而我们的方法同时适用于横向位移和圆周位移（在360度以内）。另一项研究采用函数主成分分析，以补偿传感器本体位置变化所导致的数据变化 [28]。一项研究通过最大化期望，以无监督方式估计特征分布，从而建立了用于估计分布偏移量并调整原始分类器的机制 [6]。上述工作 [6, 19, 28] 一致表明，随着位移程度增大，性能会下降。Banos等人使用层次加权分类器动态搜索可用特征 [4]。一些研究人员倾向于寻找与传感器位置无关的特征。Forster等人采用遗传算法，提取与位置偏移无关的特征，用于运动类型分类任务 [18]。另一种解决方案是扩大感测区域 [13]。由于感测区域扩大，在传感器发生位移的情况下，感测会更加稳健。总而言之，传感器位移已被确定为导致性能下降的关键因素之一，现有研究也探索了多种解决方案来解决这一问题。由于柔性传感器具有形变特性，在以下情况下实现稳健的模式识别会更加复杂

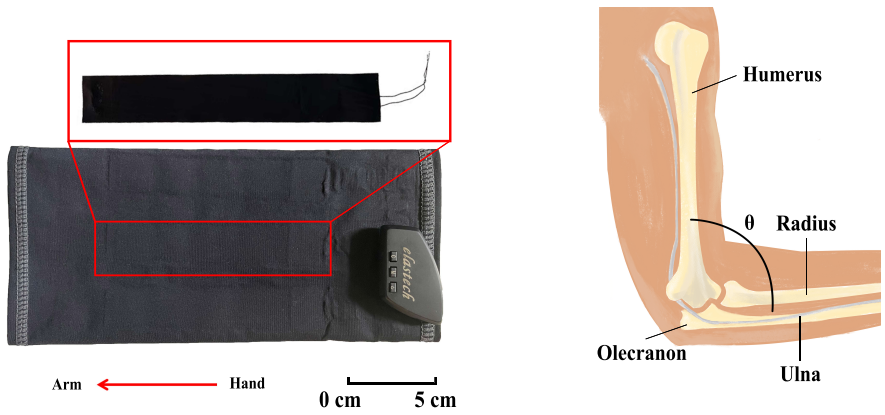

(a) (b)

图 2. (a) DisPad 的外观,红色箭头表示佩戴方向。(b) 肘关节弯曲角度示意图肘关节。

放置偏差。我们的方法旨在应对肘垫的大幅圆周位移和横向设备位移所带来的挑战，并获得稳健的关节追踪性能。

3 方法

令 D_{SS} 为一个数据集，其中包含一名单用户在不同 DisPad位置采集的传感器数据及对应的真实值；D_{SM} 为一个数据集，其中包含上述同一名单用户在仅三个 DisPad位置执行四种不同动作时采集的数据；D_{MM} 为一个数据集，其中包含十名用户在仅三个 DisPad位置执行随机动作时采集的数据；D_{NM} 为一个数据集，其中包含 D_{SM} 中一种动作的数据，但没有标签；D_{NU} 为一个数据集，其中包含 D_{MM} 中一名用户的数据，但没有标签。我们的目标是在存在传感器位移的情况下推断人体关节弯曲角度 θ，并将此方法推广至其他用户和动作。这里，我们将 D_{SS} 定义为源域，将 D_{NM} 和 D_{NU} 定义为目标域。

3.1 概述

我们的工作基于标准柔性垫和由六个柔软且可拉伸传感器组成的稀疏网络，设计并开发了一个原型 DisPad（图2a）。我们的方法旨在根据柔性传感器的传感器读数，估计肘关节的弯曲角度，θ（图2b）。此外，对于新用户或新动作，我们的方法无需采集光学真实值，即可稳健地预测其运动角度。我们将弯曲角度定义为矢状面上肱骨与桡骨和尺骨之间中心线所成的角度（图2b）。

我们将在两种不同的使用场景中研究这一问题。一种场景是单用户收集了传感器数据及对应的真实值，并使用了各种 DisPad位置；另一种场景是针对新动作/用户，仅有少量随机 DisPad位置（图3）。请注意，新动作/用户的真实值未知。对于单用户，我们首先收集垫片在各种横向位移和圆周位移下的传感器读数。同时，光学动作捕捉（MoCap）系统记录肘部弯曲角度，作为真实值。然后，我们通过最小化真实值与估计关节角度之间的均方误差损失来训练 LSTM模型。

为解决不同用户和运动类型之间的差异，我们为新用户和新运动设计了校准阶段。具体而言，在此阶段，我们采用基于模糊熵的排序方法，以及基于LSTM模型的迁移学习。首先，计算每次位移过程中每个传感器读数的模糊熵值

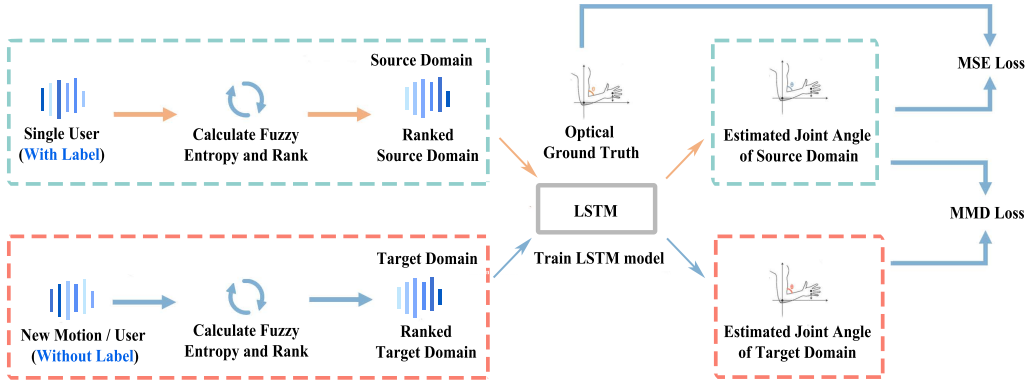

图 3。方法概述。请注意，我们利用六条垂直线，并通过不同的颜色深浅来表示 si 的大小传感器读数’信息熵。 x

算法 1： DisPad：无监督迁移学习

输入： D_{SS}，新用户 D_{NU} 或新动作 D_{NM} 在一个 DisPad 位置处的数据，以及 $D_{TrainSource} = []$

输出： 新用户或新动作的运动角度 θ

$L^n = [l_1^n, l_2^n, ..., l_6^n]$ ←D_{NU}/D_{NM} 的六个传感器读数的索引；

计算 D_{NM}/D_{NU} 的模糊熵；

$D^{TrainTarget}$ ←按照模糊熵矩阵从小到大对 D_{NU}/D_{NM}进行排序；排序索引 $\hat{L^n} = [\hat{l_1^n}, \hat{l_2^n}, ..., \hat{l_6^n}]$；

对于*DisPad* 的每个位置$\mathcal{D}_{SS}$ **执行**

  $V^s = [V_1^s, V_2^s, ..., V_6^s]$ ←此 DisPad 位置处的六个传感器读数值；

  $L^s = [l_1^s, l_2^s, ..., l_6^s]$ ←此 DisPad 位置处的六个传感器读数索引；

  计算 V^s 的模糊熵；

  $\hat{V^s}$ ←按照模糊熵矩阵从小到大进行排序，排序索引为 $\hat{L^s}$=$[\hat{l_1^s}, \hat{l_2^s}, ..., \hat{l_6^s}]$；

  如果 $[l_1^n, l_2^n] \cap [l_1^s, l_2^s] \neq \emptyset$，**则**

    $D^{TrainTarget}$ ←$D^{TrainTarget}$.append($\hat{V^s}$)

  end

结束

将 $D_{TrainSource}$ 和 $D^{TrainTarget}$ 输入长短期记忆网络；

训练长短期记忆网络，以计算 $D_{TrainSource}$ 上的均方误差损失，以及 $D_{TrainSource}$估计值之间的最大均值差异损失以及 $D^{TrainTarget}$；

以根据每个 DisPad 位置处的模糊熵矩阵对不同传感器读数进行排序。其次，对LSTM模型进行迁移学习，以缩小新用户或运动数据与原始训练数据集之间的差距。也就是说，根据源域和目标域的输出层（估计关节角度）计算最大均值差异（MMD）损失。此外，在源域中计算均方误差（MSE）损失，以确保神经网络的预测能力。

3.2 用于校准的无监督迁移学习

基于 D_{SS} 构建模型后，我们引入了无监督迁移学习技术，使训练好的模型适应更具挑战性的条件：在多动作和多用户场景中存在未知设备位移，且无需使用专业的动作捕捉系统采集真实值。这项技术支持无监督校准，并确保 DisPad 在真实应用中的使用灵活性。

鉴于 $\mathcal{D}_{SM}$ 和 $\mathcal{D}_{MM}$ 仅包含少量 DisPad 位置，我们决定在 $\mathcal{D}_{SS}$至 $\mathcal{D}_{SM}$ 和 $\mathcal{D}_{MM}$上进行迁移学习。然而，直接迁移很困难，因为用户佩戴 DisPad 时可能存在任意位移，导致新用户和新动作对应的 DisPad 位置未知。因此，迁移学习需要同时处理传感器位移以及新动作/用户的不同模式。为解决这一问题，我们首先采用传感器排序，使传感器信号在每个 DisPad 位置下都保持一致，然后通过迁移学习使模型能够预测 $\mathcal{D}_{SM}$ 和 $\mathcal{D}_{MM}$ 的不同分布。具体而言，校准过程包括两个步骤：1）使用模糊熵指标对传感器读数进行排序；2）针对未知的 DisPad 位置条件微调预训练模型（迁移学习）。算法 1 展示了我们的方法的伪代码。

3.2.1 基于模糊熵的传感器排序。如图4b 和4d 所示，与靠近鹰嘴侧的传感器相比，远离鹰嘴侧的传感器往往线性度更低、噪声更多。此外，可以观察到，每个传感器的线性度各不相同，线性度较低的传感器读数更有可能

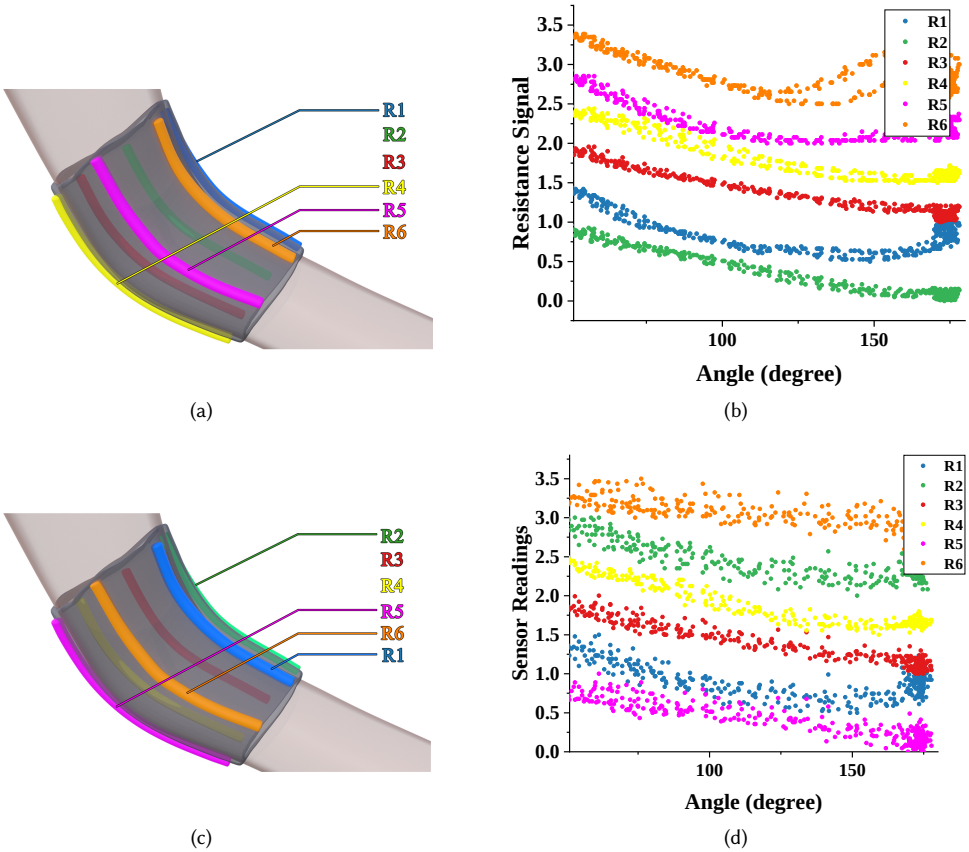

图4. 不同传感器放置位置下的传感器读数变化。请注意，我们已对所有传感器读数进行归一化处理，并通过添加不同的标量将它们分开，以使图示更清晰。(a) R2 和 R3 位于肘突侧面的布置。传感器读数对应位置 (a)。(c) R3 和 R4 位于鹰嘴侧面的布置。(d) 传感器读数对应位置 (c)。

伴有噪声。此外，弯曲角度之间的映射更加混乱，并会产生一对多映射。因此，线性度较低的传感器无法充分表征用户的运动模式。由于横向位移和圆周位移会导致传感器位置发生变化，靠近鹰嘴的传感器也会有所不同。因此，发生传感器位移时，表征较强运动模式的传感器也会改变。这种变化会使网络混淆，降低预测效果。因此，我们提出通过排序操作，使能够充分表征运动模式的传感器读数和表征能力较弱的传感器数据始终处于相同位置。如此一来，能够充分表征运动模式的传感器读数和表征能力较弱的传感器读数便始终处于相同位置。因此，可以减少网络的混淆。由于较低的线性度和更多的噪声代表传感器信号的无序性（即信号重复先前模式的可能性较低），我们决定采用模糊熵 [9] 来衡量每个 DisPad 位置处各传感器读数的复杂度，进而判断该传感器能否充分表征用户的运动模式。

用于分析表面肌电图（肌电图）信号的模糊熵算法 [9] 用于衡量时间序列数据的复杂度。对于一个传感器读数构成的有限时间序列$\{x(i)\colon 1 \le i \le N\}$(大小 N)，给定窗口大小 m，该序列可形成向量序列 $\left\{\mathrm{x}_i^m, i = 1, \ldots, N - m + 1\right\}$，模糊熵可通过以下公式估算：

$$\text{Fuzzy En}(m, r, N) = \ln \phi^m(N, r) - \ln \phi^{m+1}(N, r), \tag{1}$$

$$\phi^m(N, r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \frac{1}{N-m} \sum_{j=1, j\neq i}^{N-m+1} D_{ij}^m, \tag{2}$$

$$D_{ij}^m = \exp\left(-\left(d_{\mathrm{ij}}^m\right)^N / r\right), \tag{3}$$

其中，r是原始时间序列的标准差，d_{ij}^m是 x_i^m 与 x_j^m 之间的最大绝对差值。

通过计算每个传感器的模糊熵，我们可以根据熵矩阵对不同传感器的读数进行排序，并将其作为新的输入。对于 DisPad 位置 $X = [x_1, x_2, ..., x6]$ 处的六个传感器读数，此过程可表示为：

$$\hat{\mathrm{X}} = R(\mathrm{X}, \text{Fuzzy En}(m, r, N)) \tag{4}$$

其中，R 表示排序操作，FuzzyEn 表示当前 DisPad 位置处六个传感器读数的模糊熵矩阵。这样一来，即使发生传感器位移，也始终可以按照各传感器对运动模式的表征强度排列六个传感器的输入，从而减小传感器位移的影响。请注意，排序操作在每个 DisPad 位置仅执行一次。此外，为了更公平地捕捉每个传感器数值的变化并减小噪声的影响，我们对数据进行了最大最小归一化，并在计算熵之前移除了数值离群点 [43] 。

3.2.2 优化预训练模型。 我们采用迁移学习，使模型能够泛化到具有不同运动模式的其他数据集。

训练流程。 我们对参数 D_{SM} 和 D_{MM} 统一采用相同的参数设置。这些参数设置见附录。对于上述用户迁移和动作迁移场景，我们采用相同的 LSTM 模型结构，该模型在 D_{SS} 上训练。

损失定义。 与 [57], 相同，我们采用了包含五种以上不同高斯核的多核最大均值差异（多核 MMD）来衡量源域与目标域之间的距离 [57]。MMD 将源域和目标域的分布映射到再生核希尔伯特空间中，从而得到两个分布之间的距离 [26, 27]。为更好地估计分布差异，我们在低维输出层进行领域自适应 [57]。因此，我们的最大均值差异损失可表示为 [26]

$$\begin{aligned} L_{\mathrm{mmd}} =& \left\| \mathbb{E}\left[\psi\left(\hat{Y}_s\right)\right] - \mathbb{E}\left[\psi\left(\hat{Y}_t\right)\right] \right\|_{\mathcal{H}}^2 \\ =& \frac{1}{m^2} \sum_{i,j=1}^{m} k\left(\hat{y}_i^s, \hat{y}_j^s\right) - \frac{2}{mn} \sum_{i,j=1}^{m,n} k\left(\hat{y}_i^s, \hat{y}_j^t\right) \\ &+ \frac{1}{n^2} \sum_{i,j=1}^{n} k\left(\hat{y}_i^t, \hat{y}_j^t\right), \end{aligned} \tag{5}$$

其中， $\hat{Y}_s$ 和 $\hat{Y}_t$ 分别表示源域和目标域的估计值。 $\hat{y}_i^s \in \hat{Y}_s$（$i$ =1、2、.....、 m）和 $\hat{y}_i^t \in \hat{Y}_t$（$i$ = 1、2、.....、n）分别是 $\hat{Y}_s$和 $\hat{Y}_t$的样本。 ψ（Y）表示Y在再生核希尔伯特空间 H 中的特征嵌入， k 是高斯核函数 [27]。 L_{mse} 是 D_{SS} 的标准损失。 L_{mmd} 是输出层源域与目标域之间的损失。于是，总损失表示为：

$$L = L_{\text{mse}} + \eta \cdot \lambda \cdot L_{\text{mmd}}, \tag{6}$$

其中， η 是加权参数， λ 是随神经网络迭代而变化的学习率衰减参数，在训练集 [57]的早期阶段优先最小化 L_{mse}：

$$\lambda = \frac{2}{1 + e^{\frac{-10 \times i}{m}}} - 1 \tag{7}$$

$$\lambda = \frac{2}{1 + e^{\frac{-10 \times i}{m/10}}} - 1 \tag{8}$$

其中，m 是一个超参数。由于我们的 $\mathcal{D}_{SM-TR}$ 和 $\mathcal{D}_{MM-TR}$ 数量较少（在我们的实验中为 2000），模型收敛非常快。因此，在前 5 个训练轮次中，我们采用公式 7。随后几个训练轮次中，我们使用公式 8 。我们已在附录中列出 m 和 λ 的取值。

选择用于训练的源数据。得益于基于熵的排序操作，我们使不同位置的传感器数据更加一致。这意味着我们不必将来自 D_{SS} 的所有数据都视为源域，因为不同偏移位置的方差已经降低。然而，为了提升网络的泛化能力，当当前 DisPad 位置处 D_{SS}的前两个熵排序索引与 D_{NU}/D_{NM}的前两个熵排序索引相交时

4 实现

4.1 系统原型

我们在标准肘垫上加装了六个柔性可拉伸传感器，它们沿肘部周围呈圆形均匀分布（图2a 和图5a）。手臂方向与袖套方向平行，且只能按照图2a中箭头所示的方向穿戴。结果部分的一项进一步实验讨论了构建原型时传感器数量的直觉依据和合理性。这些织物传感器采用电容式原理，且

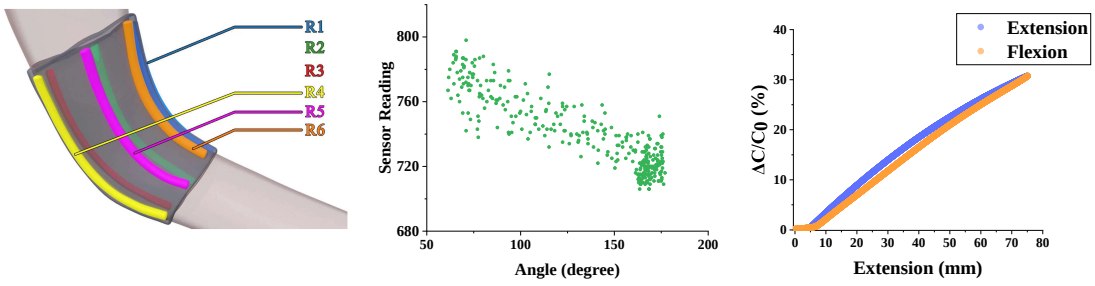

(a) (b) (c)

图 5. (a) 一块 材料，其中 R2 位于肘部鹰嘴一侧。(b) 传感器读数对应于位置 (a) 在 g
屈曲和 肘部伸展期间。(c) 传感器读数（垂直方向标记为 R）随伸展程度而变化。

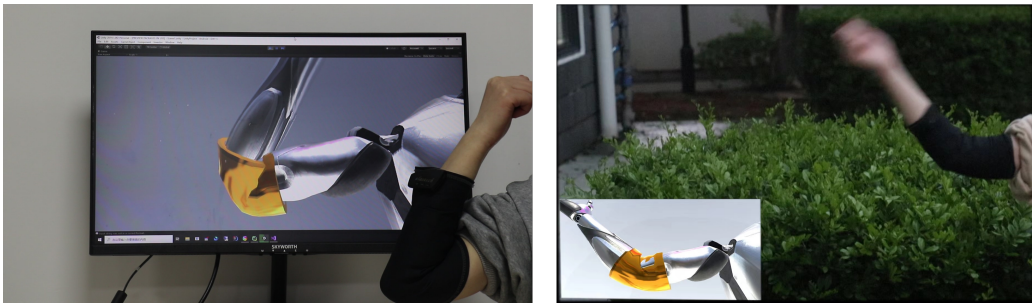

图 6. 可视化的人　体关节运动，左图使用电脑显示器，右图使用手　　机。

可作为现成产品从 ElasTech 购买 [1]。产品手册指出，传感器可手洗 100 次以上，机洗 60 次以上。

图 5b 展示了单个传感器在常规使用过程中读数的变化。可以观察到，传感器读数会随传感器位移的不同而变化。图4 展示了不同传感器放置位置下的传感器读数。结果表明，对于特定的设备位移，鹰嘴侧面的传感器会在肘部弯曲（角度减小）时被拉伸，产生更大的电容，从而建立传感器读数与肘关节角度之间的线性映射。相比之下，其他传感器呈现出更复杂且混乱的模式。

传感器读数以 50Hz 的帧率通过低功耗蓝牙无线传输。电容值在 [0, 1023]内转换为数字形式。电路板由传感器供应商 *ElasTech*设计，并通过蓝牙将数字化的传感器信号发送至手机（华为 Mate 20，内存：6GB，安卓版本：9）。随后，数据会进一步传输到远程服务器，由其执行 LSTM模型的训练或加载过程。该电路可通过蓝牙适配器将数据直接发送至台式电脑。服务器配置为单核中央处理器、不支持图形处理器，内存容量为 2GB。操作系统为 64 位 Ubuntu 16.04。

4.2 数据集准备

数据集准备过程可分为三个阶段：1）一名受试者在不同设备放置位置下进行肘部弯曲。采集的数据集 D_{SS} 用于标准情况下学习模型的训练集和测试；2）一名受试者进行四种运动类型（跑步、行走、跳跃、拍手），以验证我们的方法在不同运动类型下的表现。采集的数据集命名为 D_{SM}；3）招募一组参与者，通过多受试者实验验证我们的方法，采集的数据集命名为 D_{MM}。整个过程经厦门大学医学伦理委员会批准。数据采集前，我们向参与者说明实验目的和流程，并取得了他们的书面知情同意。在此，我们将垫片沿横向和环向维度的位移分别定义为 η 和 β。

4.2.1 单受试者单运动数据集 $\mathcal{D}_{SS}$ 准备。

参与者。 我们邀请了一位参与者（男性，31岁）准备训练数据集。该参与者（下文称为 P1）是作者所在机构的一名工程师。该参与者的臂围为 24.75 厘米。我们进行了一次预试验，以评估垫片的穿戴体验和传感器的伸展能力（使肘垫贴近手臂，从而让传感器能够有效伸展

[1] http://www.elas-tech.com/

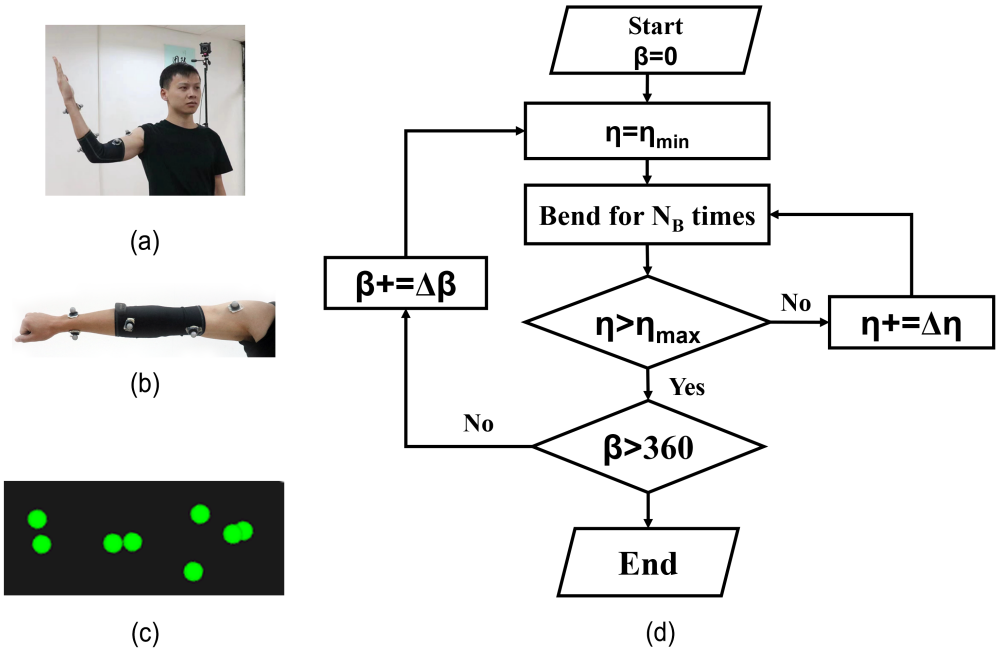

图7。(a) 我们的参与者身处动作追踪工作室。(b) 带有反光标记的 DisPad。(c) 追踪软件捕捉到的标记点。(d) 训练数据的采集过程。

）。结果显示，预期臂围范围为 20.5 至 28 厘米。这确保了数据采集过程中穿戴舒适。

流程。该流程已获厦门大学医学伦理委员会批准。参与者P1佩戴垫片进入动作追踪工作室（图7a）。垫片上加装了反光标记，由红外摄像机进行追踪（图7b）。Nokov动作捕捉系统以 60 帧/秒的帧率追踪并计算标记点的三维位置（图7c）。根据图7c 中追踪到的位置，我们可以计算上臂与前臂中心线之间的向量，这两个向量之间的夹角即为肘关节的旋转角度。我们通过同时触发两个软件程序，将传感器采集的信号与动作捕捉系统记录的关节角度同步。由于这两种信号源的帧率不同，我们对关节数值进行降采样，以确保样本数量一致。本文后续的数据准备流程均采用了这些处理方法。

在采集单受试者单运动数据集 D_{SS} 时，参与者的动作序列设计如图7d 所示。圆周位移范围为 $\beta \in [0\circ, 360\circ]$,，这表示我们考虑了多种灵活性，允许用户基本不受限制地旋转垫片。我们将肘突定义为起始位置，不过起始位置可以是上臂与前臂交界处周围圆上的任意一点。横向位移范围定义为 $\eta \in [\eta_{min}, \eta_{max}]$，其中 η_{max}-η_{min}=4 cm。每次试验中，参与者完成 N_B=8 个弯曲周期。每个弯曲周期中，参与者以不同速度在旋转范围内（约为$\theta \in [40\circ, 180\circ]$）弯曲肘部。每次弯曲试次后，我们将垫片略微横向移动 $\Delta\eta$=1

表1. S tatistics 和数据集的划分，按 DisPad 位置 划分。

	训练集	验证集	测试	总计
$\mathcal{D}_{SS}$	378	126	135	639
$\mathcal{D}_{SM}$	4	4	4	12
$\mathcal{D}_{MM}$	10	10	10	30

cm，直到到达 η_{max}。完成一个完整的横向位移周期后，垫片旋转 $\Delta\beta = 5$，并重复上述步骤。整个采集过程总计约耗时 1.2 小时。

4.2.2 单受试者多运动数据集 $\mathcal{D}_{SM}$ 准备。

参与者。 同一位参与者参与了单受试者单运动数据集的准备流程。

流程。 在采集动作数据集 D_{SM}期间，参与者按照指示完成四种日常活动：步行、跑步、拍手和跳跃。由于人们在日常生活中经常进行这些活动，数据采集过程无需额外预训练。这些活动可作为原型应用在日常生活中的参考。步行、跑步和跳跃是日常活动，其运动幅度各不相同，因此肘关节的旋转速度和范围也有所不同。每次试验中，每种活动持续一百秒。我们在每次试验中随机对垫片进行圆周位移和横向位移后，共进行了三次试验。位移配置范围为（$\beta \in [0, 360)$, $\eta \in [\eta_{min}, \eta_{max}]$）。整个采集过程持续了22分钟。

4.2.3 多受试者多动作数据集$\mathcal{D}_{MM}$ 准备。

参与者。 我们邀请了十位受试者参与，其中五位男性为 P4，P8 – 11，五位女性为 P2，P3，P5 – 7。他们的年龄介于 21 至 55 岁之间，臂围介于 20.5 至 28 厘米之间。他们都是作者所在机构的研究生。

流程。 为构建数据集 $\mathcal{D}_{MM}$，每位参与者均按照采集 $\mathcal{D}_{SM}$ 的流程进行操作，但他们在每个随机位移位置分别采集了 40 秒的数据。标记点的布置与图 7b 和图 7c 相同。采集过程总计持续 21 分钟。采集结束后，我们进行了访谈，以了解穿戴体验。

4.3 网络和训练细节

4.3.1 网络模型。 我们将估计肘关节角度的问题视为回归问题。为解决这一问题，我们构建了一个六层LSTM模型 [29]，用于拟合传感器读数与光学真实值。网络输入为30帧传感器读数（大小为30x6），输出为肘关节角度（大小为1x1）。批量大小为256，隐藏单元数也为256。学习率为0.01，每经过两个训练轮次降低10%。为避免梯度爆炸和梯度消失，我们采用了梯度裁剪。我们添加了一个批归一化层，以统一各层的数据分布。在输出层中，全连接层将LSTM层的输出转换为估计的肘关节角度。为使输出更加平滑，我们采用了误差状态卡尔曼滤波器。预测误差与测量误差之比为2.67。

4.3.2 角度预测的损失定义。 D_{SS}的传感器读数与光学真实值之间的均方误差损失计算如下：

$$L_{\text{mse}} = \frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2, \tag{9}$$

其中， $\hat{y}_i$ 表示LSTM模型的估计值， y_i 表示光学真实值。 n 是一个批次中的样本数。

4.3.3 数据统计与划分。最终的$\mathcal{D}_{SS}$、$\mathcal{D}_{MM}$和$\mathcal{D}_{MM}$数据集分别包含219,932、60,276和60,972个样本。本文发表后，数据集和代码将向公众开放。由于我们观察到原始训练数据集中圆周位移范围为 β=[160, 180] 的样本数量过多，我们在第5.1节讨论了其影响。

单用户训练。划分D_{SS} 数据集时，DisPad位置被随机分为三个划分（训练集、验证集、测试），使三个划分中的样本彼此独立。

表1 列出了数据集统计信息，以及训练集、验证集和测试集的划分情况。

迁移学习的源域。该选择可参考$\mathcal{D}_{S}ourceTrain$ 见算法1。

迁移学习的目标域。由于我们的目标是通过简单的数据采集，将模型迁移到新动作（或新用户）上，因此我们仅采用目标运动（或用户）中一个 DisPad位置的 2,000 个样本进行训练，并在其余 DisPad位置上验证结果。请注意，所有训练集的标签均已移除。

该划分可确保训练后的模型不会在训练集划分上过拟合，并且能够泛化到测试数据集中的新 DisPad位置。

每个单元格中的数值表示每种条件下 DisPad位置的数量。在接下来的讨论中，我们使用后缀（$-TR$, $-VA$, $-TE$）来表示划分（例如，D_{SS-TR}表示单受试者单运动数据集 D_{SS}的训练子集）。

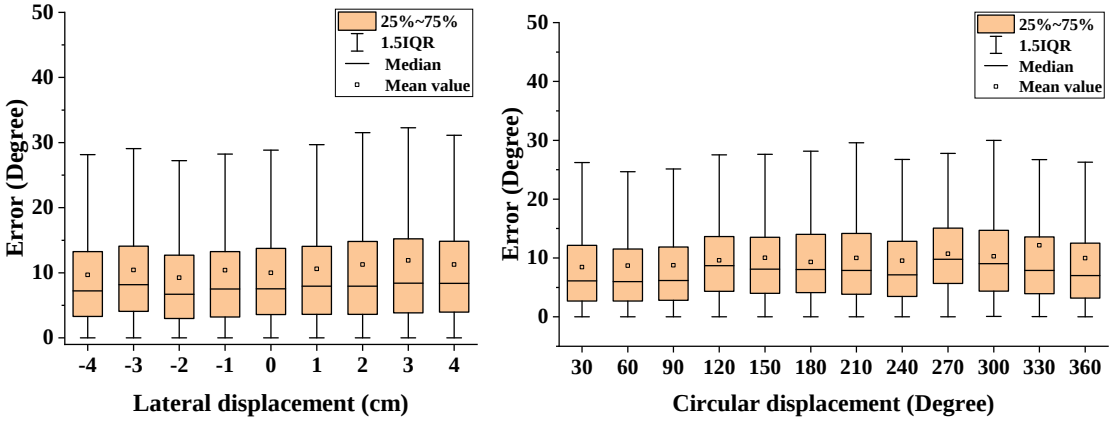

图 8. (a) 单个横向位移的平均跟踪误差 η。(b) 单个圆周位移的平均跟踪误差 β.

5 结果

5.1 单受试者单运动数据集上的追踪结果 D_{SS}

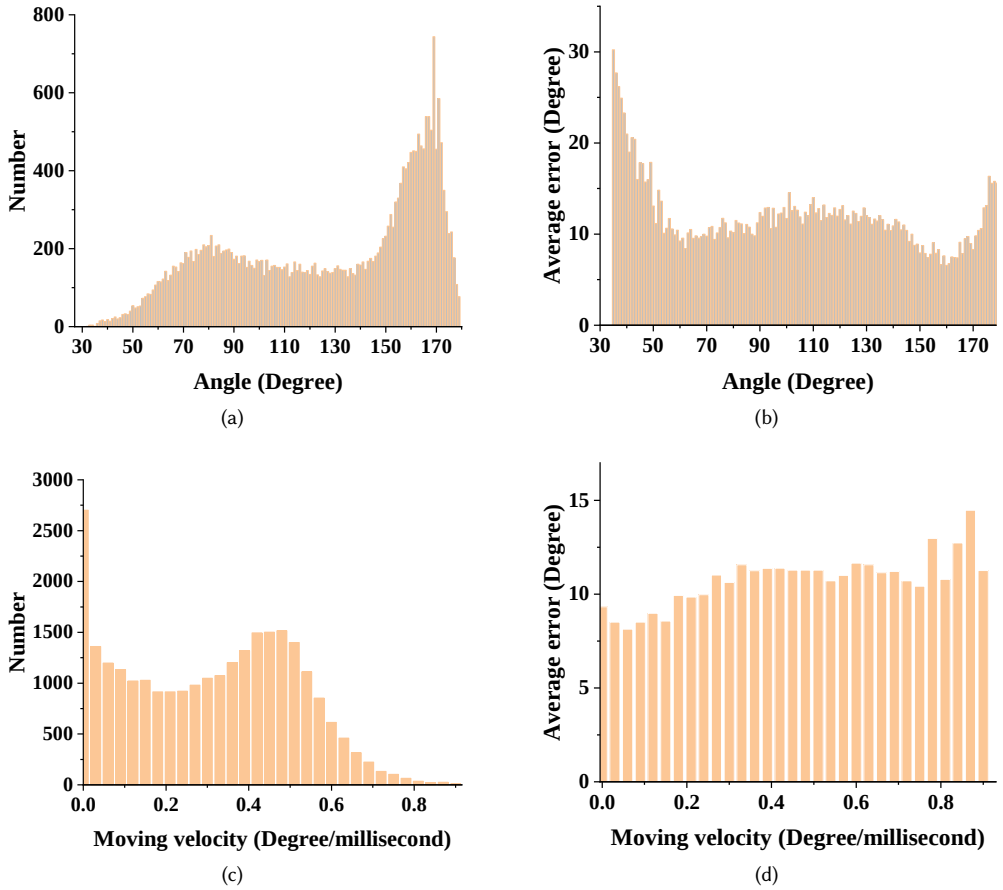

图 9. (a) 数据点数量与弯曲角度之间的关系。(b) 方法在不同弯曲角度下的跟踪误差。(c) 数据点数量与不同运动速度之间的关系。(d) 方法在不同运动速度下的跟踪误差。

在训练阶段，我们使用 D_{SS-VA} 对基于学习的模型进行优化，并计算 D_{SS-TE}上的平均跟踪误差。训练 98 秒后，在 D_{SS-TE} 中估计肘关节弯曲角度的最终平均跟踪误差为 9.82 度。

横向位移和圆周位移对应的跟踪误差如图 8a和图 8b所示，这表明横向位移和圆周位移对跟踪误差没有明显影响。这验证了我们的方法可应用于各种横向位移和圆周位移，表明我们的算法具有鲁棒性。

我们根据测试数据集评估结果，考察关节弯曲角度和运动速度的影响。关节弯曲角度和运动速度的影响分别如图9b 和图9d所示，而

不同关节弯曲角度对应的数据点数量如图9a所示。图9a 显示，关节弯曲角度的数据点主要集中在以下范围 [160, 180]。相比之下，30 度附近的数据点较少。从图9b可以看出，最大和最小跟踪误差分别出现在约 30 度和 160 度处。误差最小可能是因为 160 度附近的数据点数量较多，而误差最大可能是由于以下范围内的数据点数量较少 [30,50]。特定关节角度下的样本数量与平均误差之间的相关系数为 -0.60。这表明两者呈中度负相关，即增加样本数量可能有助于降低跟踪误差。因此，数据集中某一特定关节角度下的样本数量可能会影响误差。图9d展示了速度与平均跟踪误差之间的关系。速度的计算方法是将角度变化之和除以所用时间，时间窗口为 30 毫秒。此外，我们还进行了相关性分析，以确定运动速度与平均跟踪误差之间是否存在相关性。结果为 0.78，表明运动速度与跟踪误差之间呈高度正相关。为探究其原因，图9c 展示了数据点数量与运动速度之间的关系。从图中可以推断，0 度/毫秒附近过多的数据点会导致平均跟踪误差较低。相反，当运动速度超过 0.5 度/毫秒时，数据点数量急剧减少，并在 0.8 度/毫秒时达到最小值。这一趋势与图9d相反，后者在 0.8 处达到峰值。相关性分析表明，跟踪误差与数据点数量呈中度相关（结果为 -0.46）。因此，误差也与数据点数量有关。

5.2 单主体多运动数据集的追踪结果 D_{SM}

图10a展示了采集不同运动类型场景过程的代表性图像。肘部标记点的放置方式与图 7b 所示相同。不同运动类型与平均跟踪误差之间的关系如图 10b所示。我们还比较了使用和不使用迁移学习时的跟踪误差。可以清楚地看到，不使用迁移学习时，拍手的跟踪误差最高，

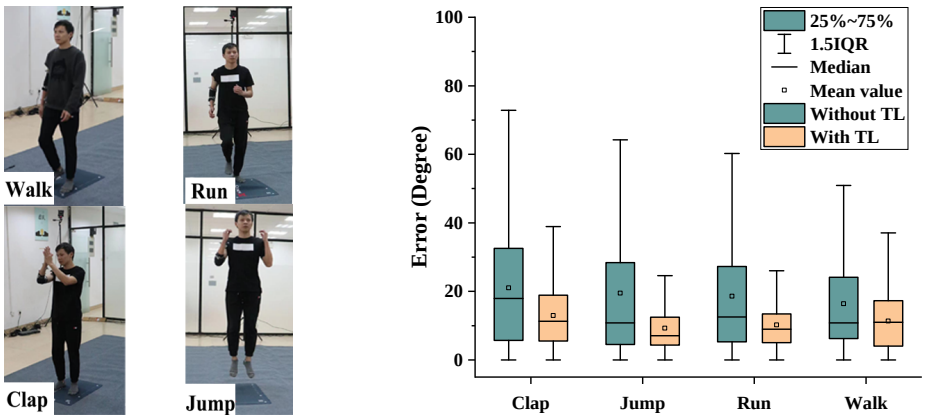

图 10. (a) 表示 运动类型的平均跟踪误差
不同运动类型的数据集 D_{SM} 中，以及迁移学习前后的效果。

平均而言，其次是跳跃，然后是跑步和步行。它们的平均跟踪误差超过十五度。此外，上限与下限之间的差值超过 40 度。

相比之下，如图 10b 所示，采用迁移学习后，四种运动类型之间的差异更小。此外，平均跟踪误差以及上限与下限之间的差距也有所减小。现在，上限低于 40 度，而平均跟踪误差约为 10 度。为了进一步衡量迁移学习的效果，我们进行了 Mann-Whitney U 检验（鉴于数据不服从正态分布（$p<0.05$）），以检验迁移学习前后跟踪误差的差异是否具有统计显著性。结果（$U=1534615168$, $p<0.001$）表明，迁移学习前后的误差存在显著差异。这证明迁移学习适用于不同运动类型的预测，并能降低不同运动类型的跟踪误差。我们还在数据集 $\mathcal{D}_{SM}$上验证了平均跟踪误差，该误差为 10.98 度。

图 11a 和 11b 展示了我们的预测结果与真实值以及基线（不使用排序熵和迁移学习）的对比，结果是在 $\mathcal{D}_{SM}$上获得的。可以观察到，图 11a 中存在不同的运动模式，且每种动作的样本都相似。尽管基线的预测结果与真实值的形状大致相似，但在运动范围方面，基线的预测不如我们的方法准确（图 11b）。这一差异意味着，由于传感器位移和新运动模式，$\mathcal{D}_{SM}$ 的数据分布与 $\mathcal{D}_{SS}$ 的不同。与基线相比，我们的模型在这些不同模式上具有更好的泛化能力。

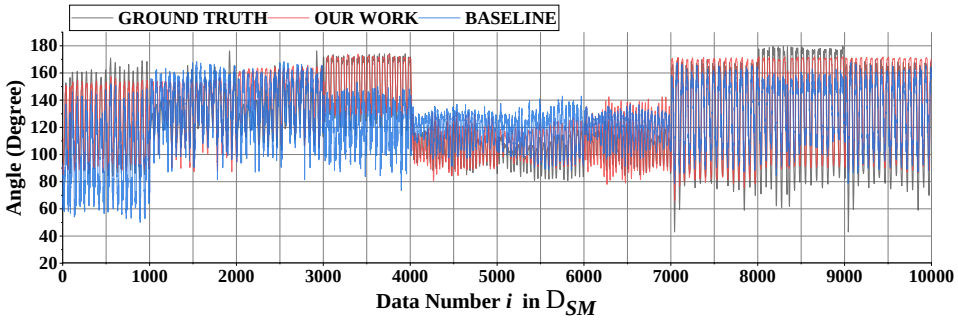

(a)

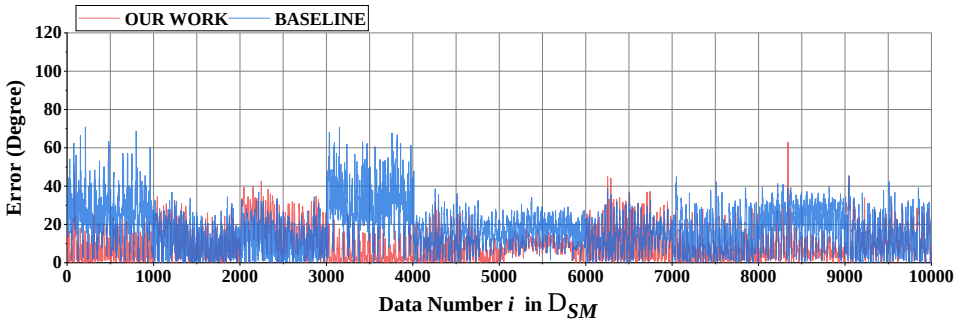

(b)

图 11。（a）D_{SM} 上详细预测结果的图示。（b）D_{SM} 上详细预测误差的图示。

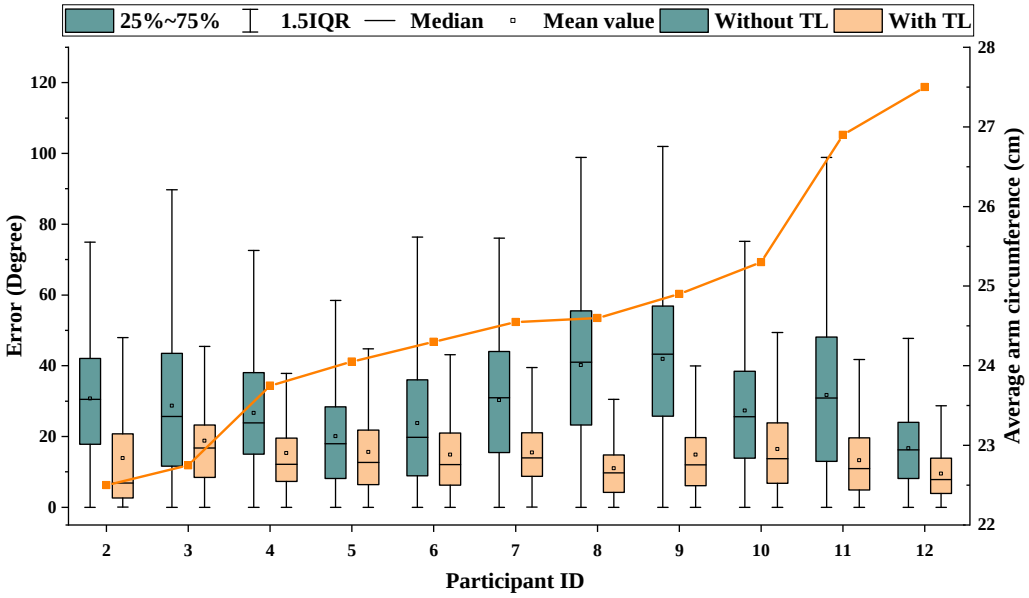

图 12. 各参与者的跟踪误差和臂围。

5.3 多受试者多动作数据集的追踪结果 D_{MM}

由于我们基于参与者 $\mathcal{D}_{SS}$ 构建了训练数据集 **P1**，因此我们在多受试者多动作数据集 $\mathcal{D}_{MM}$ 上测试性能，以衡量 DisPad 对用户的泛化能力。如图12所示，十位用户在未使用迁移学习时的跟踪误差明显不同。然而，应用迁移学习后，跟踪误差及其范围均显著降低。我们进行了曼-惠特尼U检验（鉴于数据不服从正态分布（p 值 <0.05）），确认迁移学习前后的误差存在显著差异（U=1383015500.00，p<0.001）。

通过迁移学习，数据集$\mathcal{D}_{MM}$ 上的平均跟踪误差为 11.81 度。这表明该方法在不同用户间具有鲁棒性。为探究用户的臂围值与跟踪误差之间可能存在的关系，我们测量了相应用户的平均臂围（上臂围和下臂围的平均值）。相关数据也显示在图12中。迁移学习后的用户臂围与平均跟踪误差之间的相关性为 0.11，表明二者呈弱正相关。这并不令人意外，因为**P1**的臂围为 24.75 厘米，小于大多数其他用户的臂围。因此，在这种情况下，较小的臂围会带来更好的预测结果。

图 13a 和13b 展示了在 $\mathcal{D}_{MM}$ 上的预测结果。与图 11a 相比，由于每位用户在短时间内执行的动作都是随机的，动作的移动范围和持续时间更加复杂。由于上述原因，基线未能准确预测移动范围，导致其误差比我们的模型更大（图13b）。相比之下，我们的模型表现优于基线，并且在 $\mathcal{D}_{MM}$ 上具有良好的泛化能力。

5.4 穿戴体验反馈

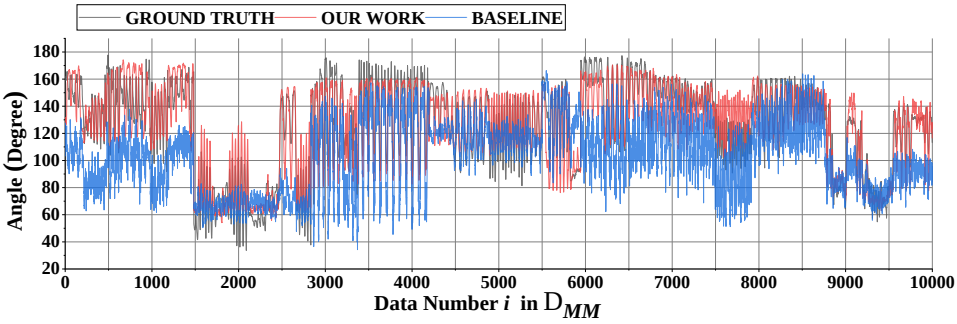

(a)

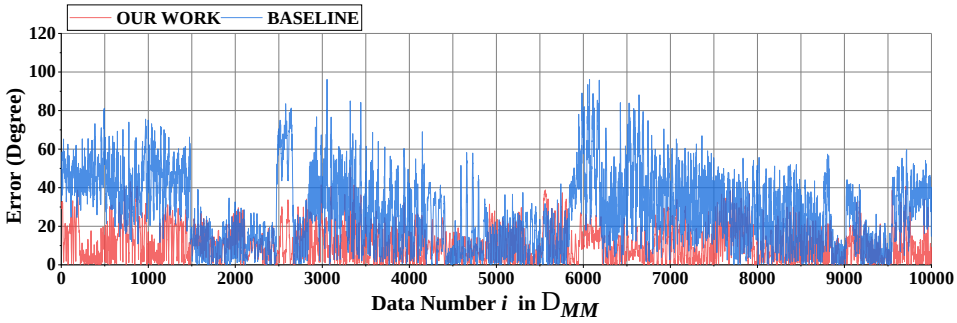

(b)

图13。(a) D_{MM}上详细预测结果的图表。(b) D_{MM}上详细预测误差的图表。

在采集数据集 D_{MM} 后进行的访谈中，大多数用户表示，穿戴 DisPad 很舒适，也不会妨碍他们做动作。不过，P11 认为穿戴体验还不错，但 DisPad 产生的压力越来越大，导致活动不便。他还表示，可以通过制作更大尺寸的 DisPad 来改善这一点。P3 也认同这一看法：“如果能借助某些技术调整尺寸，以适应臂围不同的人群，那就更好了。”

为验证该方法在新用户中的追踪效果，我们邀请了九位用户（记为P12至P20）参与评估并进行视频拍摄，他们的臂围介于20.5cm至28cm之间。流程如下：首先，他们佩戴肘垫进行校准（校准包括收集2,000个数据样本，用于排序和训练迁移模型）。通常，校准过程仅持续2.7分钟（包括收集2,000个数据样本的过程）。请注意，每位用户只需校准一次，之后即可在不同位移情况下佩戴DisPad，无需再次校准。校准完成后，这些用户可以一边观看视觉效果，一边弯曲手臂。最后，我们拍摄了视频，以展示追踪效果。此外，整个流程均经厦门大学医学伦理委员会审查并批准。在访谈和视频拍摄前，我们向每位参与者说明了实验目的和流程，并取得了他们的书面知情同意。

实验结束后，我们访谈了参与者，以了解他们的穿戴体验、肘部是否影响用户的动作，以及可视化结果是否准确。访谈期间，所有用户都表示肘垫穿戴舒适，不会影响动作。

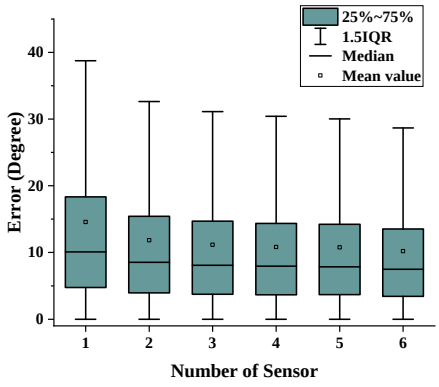

图14. 平均跟踪误差随传感器数量变化。

“穿戴体验很舒适，松紧适中，不会有挤压感。穿戴时我能够正常活动。”（P12）

“穿戴时没有不便。材料不厚，夏天穿也可以接受。”（P9）与此同时，大多数用户认为跟踪效果准确，除了P16，他指出有时会出现轻微抖动。

“总体而言，可视化效果与我的动作一致。不过，可视化有时会出现轻微抖动。”

5.5 不同传感器数量下的跟踪结果

我们的原型的感知能力源于关节弯曲角度引起的传感器拉伸。图 4展示了不同位置的传感器读数，表明关节弯曲角度会导致2-3个传感器的读数显著变化。这些传感器位于鹰嘴侧面的半圆形区域，关节旋转时该区域会被有效拉伸。相比之下，肘突侧面的传感器不会被拉伸，读数变化也不明显。鉴于圆周位移的完整范围以及最大4厘米的横向位移，我们的方法应能有效覆盖这一半圆形拉伸区域。因此，传感器数量预计为3-6个。

我们还对使用不同数量传感器时的结果进行了数值比较（图 14）。报告的误差是所有传感器选择组合的平均值。例如，选择五个传感器进行预测时，我们会随机排除一个传感器，重新构建预测模型，并重复此过程六次。从这些发现可以得出，准确度会随着传感器数量的增加而提高。不过，当传感器数量为四个或五个时，增长率较低。这表明在这一范围内，准确度没有显著变化。因此，使用三个传感器就足以以相对较高的准确度预测关节角度。

5.6 不同学习方法的比较

我们还在数据集 D_{SS} 上比较了未使用迁移学习的序列模型和非序列模型。这些方法包括 LSTM（带有额外的批归一化层）、LightGBM、CNN 与 LSTM 的组合（下文简称 CL），以及全连接神经网络（FCN）。
LSTM 降低了梯度

表2. 我们的方法与其他学习方法的比较。

方法	我们的方法	CL	LightGBM	FCN	随机森林
训练时间	98s	422.6s	1.2s	47s	378s
运行时间	0.001ms	0.000001ms	0.019ms	0.001毫秒	0.316毫秒
D_{SS-TE}上的误差	9.82	11.40	15.91	11.39	17.40
D_{SS-VA}上的误差	9.96	12.17	16.04	12.61	18.66
D_{SS-TE}上的方差	93.93	161.50	137.31	121.28	315.58
D_{SS-VA}上的方差	100.58	184.71	158.19	134.72	332.63

表3. 与其他排列方法的比较。

	无排名（度）	抖动（10^4度/秒^3）	SD（度）	模糊熵（度）
D_{SS-TE}	9.82	11.56	12.22	10.66
D_{SS-VA}	9.96	12.48	13.86	11.92
D_{SM-TE}	18.82	14.51	12.93	10.98
D_{SM-VA}	16.59	15.84	11.25	10.27
D_{MM-TE}	27.96	28.48	18.95	11.81
D_{MM-VA}	29.34	25.17	16.06	12.53
耗时	0s	6.1*e-5s	5.5*e-5s	0.022s

爆炸和梯度消失的概率。CNN 与 LSTM 的组合是一种处理人体运动数据的常用模型 [46]。LightGBM 被认为是一种强大的模型，能够缩短训练时间，同时保持良好的预测能力[32]。全连接神经网络（FCN）是深度学习中的经典模型。随机森林 [5] 是一种基于决策树的集成学习算法。对比结果见表2。它们都是机器学习领域中广受欢迎的方法。可以观察到，我们的方法、CL、LightGBM、FCN 和随机森林在平均跟踪误差和方差方面各不相同。尽管 LightGBM 的训练时间较短，但我们的方法在平均跟踪误差和跟踪误差的方差方面优于其他方法，且训练仅需 98 秒。由于其他方法在训练时间上并未显著领先，且平均跟踪误差均未低于我们的方法，因此我们选择 LSTM 作为我们的方法。

5.7 不同排序方法的比较

为了找出重新排列数据的最佳策略，我们采用标准差、模糊熵、抖动（表示平滑性和自然性的缺失，即位置的三阶导数 [17]）以及不排序这几种排序准则开展实验。我们分别在数据集 $\mathcal{D}_{SS}$、$\mathcal{D}_{MM}$和 $\mathcal{D}_{SM}$上进行测试。从表 3可以看出，除 $\mathcal{D}_{SS-TE}$ 外，模糊熵在所有数据集上的表现都优于其他方法，但计算模糊熵耗时最长。这意味着，当用户收集了自己的数据集后，无需

采用模糊熵来置换特征。不过，当用户想要进行其他动作或出现新用户时，就需要采用模糊熵来调整特征。

5.8 延迟性能

总延迟约为 40 ms，可分为四个部分。第一部分是电路板的采样间隔，电路板每 20 ms 传输一次数据。第二部分是 LSTM模型估计关节角度的前向传播过程，该过程产生 0.001 ms 的延迟。第三部分是卡尔曼滤波器，耗时 0.05 ms。第四部分是网络延迟。由于服务器和移动端蓝牙发射器通过 TCP网络连接，延迟取决于网络信号的质量。在我们的实验中（使用本地无线局域网进行），服务器—移动端和服务器—计算机阶段的延迟分别为 2 ms 和 17 ms。

5.9 总结与讨论

总而言之，我们的方法在 D_{SS},D_{SM} 和 D_{MM} 上均表现稳健，且延迟较低。此外，将传感器减少到三个时，准确度损失也较小。尽管当前的肘垫仅适用于臂围在 20.5 cm 至 28cm 之间的用户，但可以通过开发不同尺寸的肘垫来解决这一问题。此外，不同用户的穿戴体验都很好，并且不会影响臂围在 20.5cm 至 28cm 之间的用户的动作。在用户评估访谈中，所有用户也都认可 DisPad 的舒适性。此外，他们认为 DisPad 准确度较高，因为在整个体验过程中，DisPad 都能跟上他们的动作。然而，关于抖动问题，可能有两个原因：（1）肘垫在数据采集过程和实时追踪过程中会产生一些褶皱，从而引入噪声；（2）该模型只能拟合传感器值与真实值之间的近似函数关系。因此，在实时使用过程中会出现跟踪误差。这两个问题都很有意义，解决这些问题将有助于在未来工作中提升实时追踪工具的效果。

6 讨论

6.1 本文的局限性

在这项工作中，我们提出了一种基于学习的方法来应对传感器位移，并对其在多种动作和多名用户中的表现进行了验证。然而，我们发现仍有一些方面需要改进。

首先，仅检测一个自由度角度是不够的。虽然我们假设肘关节受铰链约束，即只能绕一条轴屈曲和伸展；但实际的肘关节远比单一自由度（自由度）复杂。我们观察到桡骨绕着尺骨（图2b）旋转，从而使前臂能够旋转。因此，要解决这一问题，检测多个关节有助于获取相关关节的充分信息，这对于分析由这些先前被忽略的自由度所造成的复杂信号模式至关重要。其次，当现有用户想要执行一种新动作，或出现新用户时，我们需要采集额外的传感器数据来进行迁移学习。然而，与每次使用都需要校准的惯性测量单元相比，我们的方法只需采集此类数据一次。

6.2 Com 与其他基于织物的追踪方法比较 M 方法

我们讨论了我们的方法与若干最先进的织物式跟踪系统之间的差异 [14, 34, 38]。一项研究使用长短期记忆深度神经网络，将传感器信号与全身姿势关联起来 [34]。

他们报告称，根据估计关节位置与基线关节位置之间的欧几里得距离计算，跟踪误差为 1.2 至 5.7 厘米。他们的分析仅涵盖三种运动：深蹲、弯腰伸展和风车动作。另一项研究考察了躯干和肩部的动作追踪，平均误差达到 9.4 度[14]。尽管这两项研究都取得了出色的跟踪性能，但它们未能充分分析误差对传感器位移这一因素的敏感性。近期的一项研究 [38], 与我们的工作最为相关，其在肘关节上的平均跟踪误差为 9.69 度。他们还进一步考察了传感器偏离理想位置 1 厘米时的跟踪性能，结果显示平均跟踪误差增加了约 10 度（即误差升至约 20 度）。相比之下，在传感器放置位置各不相同、且位移远超 1 厘米的多种配置下，我们在不同运动类型中的误差为 10.98 度；采用迁移学习时，在不同用户中的误差为 11.81 度。这证实了我们的方法在应对传感器位移问题时具有鲁棒性。

7 结论

我们介绍了 DisPad。它在纺织垫上采用由柔性传感器组成的稀疏网络，无论身体佩戴设备的位置如何变化、动作有何不同或用户有何差异，都能稳健地估计肘关节角度。为应对传感器位移，我们采用 LSTM模型来估计肘关节角度。此外，我们采用迁移学习来处理不同的运动类型和不同的用户。为减少迁移学习中的变量数量，我们采用基于模糊熵的排序。随后，我们开展了全面实验，评估不同用户、运动状态和运动类型下的跟踪误差，并在单用户固定动作数据集上取得了 9.82 度的平均跟踪误差。此外，使用我们的原型设备，在身体佩戴位置多样的情况下，我们分别在不同运动类型和不同用户中实现了稳定的跟踪误差，分别为 10.98 度和 11.81 度。

这项工作为未来的研究开辟了几个方向。首先是减轻对人工数据采集的需求。我们可以借助近期的深度学习技术（例如生成对抗网络 [25]）生成训练数据。第二个方向是扩展我们的方法，使其能够估计全身姿势，而不仅仅是一个肘关节。运动员通常会佩戴护肘和护膝进行防护，这为我们的系统创造了理想的应用场景。使用四个关节角度（两个肘关节和两个膝关节）有望足以预测肢体关节的角度。第三个研究方向是为运动功能受损的患者开发应用。骨折患者、瘫痪性中风患者或脑瘫患者需要经历漫长的康复期，在此期间，居家自主训练是康复进展的关键。我们的方法只要求用户在大致合适的位置佩戴设备，无需专业知识，因此为有需要的用户提供了极大的便利。

参考文献

[1] Karan Ahuja、Sven Mayer、Mayank Goel 和 Chris Harrison。2021。Pose-on-the-Go：利用智能手机传感器融合与逆运动学近似估计用户姿态。载于*2021*年*CHI*计算系统中的人为因素会议论文集。1–12。[2] Morteza Amjadi、Ki-Uk Kyung、Inkyu Park 和 Metin Sitti。2016。可拉伸、可贴附于皮肤且可穿戴的应变传感器及其潜在应用：综述。《先进功能材料》26，11（2016），1678–1698。[3] Sang-HoonBae、YoungbinLee、BhupendraK Sharma、Hak-Joo Lee、Jae-HyunKim 和 Jong-Hyun Ahn。2013。基于石墨烯的透明应变传感器。《碳》51（2013），236–242。[4] Oresti Banos、Mate Toth、Miguel Damas、Hector Pomares 和 Ignacio Rojas。2014。应对传感器位移对可穿戴活动识别的影响。*Sensors* 14，6（2014），9995–10023。[5] Leo Breiman。2001。随机森林。机器学习 45，1（2001），5–32。

[6] Ricardo Chavarriaga、Hamidreza Bayati 和 José Del Millán。2013。用于基于加速度的活动识别的无监督自适应：对传感器位移和旋转的鲁棒性。Personal and Ubiquitous Computing 17，3（2013），479–490。[7] Liming Chen、Jesse Hoey、Chris D Nugent、Diane J Cook 和 Zhiwen Yu。2012。基于传感器的活动识别。IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews) 42，6（2012），790–808。[8] Qing Chen、Nicolas D Georganas 和 Emil M Petriu。2007。利用类 Haar 特征进行实时基于视觉的手势识别。载于2007年IEEE仪器与测量技术会议（IMTC 2007）。IEEE，1–6。[9] Weiting Chen、Zhizhong Wang、Hongbo Xie 和 Wangxin Yu。2007。基于模糊熵的表面肌电信号表征。IEEE Transactions on neural systems and rehabilitation engineering 15，2（2007），266–272。[10] Jean-Baptiste Chossat、Yiwei Tao、Vincent Duchaine 和 Yong-Lae Park。2015。用于手部运动检测、嵌入微流控应变传感的可穿戴柔性人工皮肤。载于2015年IEEE国际机器人与自动化会议（ICRA）。IEEE，2568–2573。[11] Maria Cornacchia、Koray Ozcan、Yu Zheng 和 Senem Velipasalar。2016。利用可穿戴传感器进行活动检测与分类的综述。IEEE Sensors Journal 17，2（2016），386–403。[12] Christopher Einsmann、Meghan Quirk、Ben Muzal、Bharath Venkatramani、Thomas Martin 和 Mark Jones。2005。可穿戴全身动作捕捉系统的建模。载于第九届IEEE可穿戴计算国际研讨会（ISWC'05）。IEEE，144–151。[13] Yu Enokibori 和 Kenji Mase。2014。利用电子纺织品传感器估计人体关节角度。载于2014年ACM可穿戴计算国际研讨会论文集。129–130。[14] Mohammad Iman Mokhlespour Esfahani 和 Maury A Nussbaum。2018。一款用于追踪上身运动的"智能"背心：任务分类与角度估计。IEEE sensors Journal 18，18（2018），7650–7658。[15] Jonny Farringdon、Andrew J Moore、Nancy Tilbury、James Church 和 Pieter D Biemond。1999。用于情境感知的可穿戴传感器徽章和传感器夹克。载于论文摘要集：第三届可穿戴计算国际研讨会。IEEE，107–113。[16] Alessandro Filippeschi、Norbert Schmitz、Markus Miezal、Gabriele Bleser、Emanuele Ruffaldi 和 Didier Stricker。2017。基于惯性传感器的运动追踪方法综述：聚焦于人体上肢运动。Sensors 17，6（2017），1257。[17] Tamar Flash 和 Neville Hogan。1985。手臂运动的协调：经实验验证的数学模型。Journal of Neuroscience 5，7（1985），1688–1703。[18] Kilian Förster、Pascal Brem、Daniel Roggen 和 Gerhard Tröster。2009。在体域传感器网络中，针对传感器位移具有鲁棒性的活动识别判别特征的演化。载于2009年智能传感器、传感器网络与信息处理国际会议（ISSNIP）。IEEE，43–48。[19] Kilian Forster、Daniel Roggen 和 Gerhard Troster。2009。通过重复出现的情境进行无监督分类器自校准：能否获得对传感器位移的鲁棒性？载于2009年可穿戴计算国际研讨会。IEEE，77–84。[20] Peter T Gibbs 和 HHarry Asada。2005。用于人体多轴关节角度测量的可穿戴导电纤维传感器。Journal of NeuroEngineering and Rehabilitation 2，1（2005），7。[21] Guido Gioberto 和 Lucy E Dunne。2012。服装集成式可穿戴传感中的服装定位与漂移。载于 2012 年第 16 届可穿戴计算国际研讨会。IEEE，64–71。[22] Oliver Glauser、Daniele Panozzo、Otmar Hilliges 和 Olga Sorkine-Hornung。2019。通过柔性可拉伸传感器阵列进行形变捕捉。ACM Transactions on Graphics（TOG）38，2（2019），16。[23] Oliver Glauser、Shihao Wu、Daniele Panozzo、Otmar Hilliges 和 Olga Sorkine-Hornung。2019。利用可拉伸传感柔性手套进行交互式手部姿态估计。ACM Transactions on Graphics（TOG）38，4（2019），41。[24] Shu Gong、Daniel TH Lai、Bin Su、Kae Jye Si、Zheng Ma、Lim Wei Yap、Pengzhen Guo 和 Wenlong Cheng。2015。高弹性黑金电子皮肤纳米贴片：高灵敏度可穿戴生物医学传感器。Advanced Electronic Materials 1，4（2015），1400063。[25] Ian Goodfellow、Jean Pouget-Abadie、Mehdi Mirza、Bing Xu、David Warde-Farley、Sherjil Ozair、Aaron Courville 和 Yoshua Bengio。2014。生成对抗网络。载于神经信息处理系统进展。2672–2680。[26] Arthur Gretton、Karsten M Borgwardt、Malte J Rasch、Bernhard Schölkopf 和 Alexander Smola。2012。一种核两样本检验。The Journal of Machine Learning Research 13，1（2012），723–773。[27] Arthur Gretton、Dino Sejdinovic、Heiko Strathmann、Sivaraman Balakrishnan、Massimiliano Pontil、Kenji Fukumizu 和 Bharath K Sriperumbudur。2012。大规模两样本检验的最优核选择。神经信息处理系统进展25（2012）。[28] Roya Haratian、Richard Twycross-Lewis、Tijana Timotijevic 和 Chris Phillips。2013。提升动作捕捉系统传感器布置的灵活性：一种信号处理方法。IEEE Sensors Journal 14，3（2013），701–709。[29] Sepp Hochreiter 和 Jürgen Schmidhuber。1997。长短期记忆。Neural Computation 9，8（1997），1735–1780。[30] Yinghao Huang、Manuel Kaufmann、Emre Aksan、Michael J Black、Otmar Hilliges 和 Gerard Pons-Moll。2018。深度惯性姿态估计器：学习利用稀疏惯性测量实时重建人体姿态。载于SIGGRAPH Asia 2018技术论文集。ACM，185。[31] Geetanjali Vinayak Kale 和 Varsha Hemant Patil。2016。基于视觉的人体运动识别与分析研究。International Journal of Ambient Computing and Intelligence（IJACI）7，2（2016），75–92。[32] Guolin Ke、Qi Meng、Thomas Finley、Taifeng Wang、Wei Chen、Weidong Ma、Qiwei Ye 和 Tie-Yan Liu。2017。Lightgbm：一种高效的梯度提升决策树。载于神经信息处理系统进展。3146–3154。[33] Ali Kiaghadi、Morgan Baima、Jeremy Gummeson、Trisha Andrew 和 Deepak Ganesan。2018。织物作为传感器：利用摩擦电纺织品实现对人类行为的无感传感。载于第16届ACM嵌入式网络传感器系统会议论文集。ACM，199–210。

[34] Dooyoung Kim、Junghan Kwon、Seunghyun Han、Yong-Lae Park 和 Sungho Jo。2018。面向软体可穿戴运动感知服的深度全身运动网络。IEEE/ASME机电一体化汇刊 24，1（2018），56–66。[35] Kai Kunze 和 Paul Lukowicz。2008。在基于运动的体上活动识别系统中应对传感器位移。载于第10届普适计算国际会议论文集。ACM，20–29。[36] Kai Kunze 和 Paul Lukowicz。2014。可穿戴活动识别中的传感器放置变化。IEEE Pervasive Computing 13，4（2014），32–41。[37] Sunghoon Ivan Lee、Jean-Francois Daneault、Luc Weydert 和 Paolo Bonato。2016。一种用于估算关节角度的新型柔性可穿戴传感器。载于2016年IEEE第13届可穿戴和可植入身体传感器网络国际会议（BSN）。IEEE，377–382。[38] Ruibo Liu、Qijia Shao、Siqi Wang、Christina Ru、Devin Balkcom 和 Xia Zhou。2019。利用计算织物重建人体关节运动。《交互、移动、可穿戴和普适技术》ACM论文集 3，1（2019），19。[39] Federico Lorussi、Enzo Pasquale Scilingo、Mario Tesconi、Alessandro Tognetti 和 Danilo De Rossi。2005。用于手部姿势和手势监测的应变传感织物。IEEE生物医学信息技术汇刊 9，3（2005），372–381。[40] Yiğit Mengüç、Yong-Lae Park、Hao Pei、Daniel Vogt、Patrick M Aubin、Ethan Winchell、Lowell Fluke、Leia Stirling、Robert J Wood 和 Conor J Walsh。2014。用于人体步态测量的可穿戴软体感知服。《国际机器人研究期刊》33，14（2014），1748–1764。[41] Jan Meyer、Paul Lukowicz 和 Gerhard Troster。2006。用于肌肉活动和运动检测的纺织压力传感器。载于2006年第10届IEEE可穿戴计算国际研讨会。IEEE，69–72。[42] Ivan Poupyrev、Nan-Wei Gong、Shiho Fukuhara、Mustafa Emre Karagozler、Carsten Schwesig 和 Karen E Robinson。2016。Project Jacquard：大规模交互式数字纺织品。载于2016年CHI计算系统中的人为因素会议论文集。4216–4227。[43] Sergio Santoyo。2017。异常值检测技术简述。《Towards Data Science》（2017）。[44] Stefan Schneegass、Mariam Hassib、Tobias Birmili 和 Niels Henze。2014。迈向服装操作系统：支持智能服装的应用开发。载于2014年ACM可穿戴计算国际研讨会论文集：附属项目。261–266。[45] Stefan Schneegass、Mariam Hassib、Bo Zhou、Jingyuan Cheng、Fernando Seoane、Oliver Amft、Paul Lukowicz 和 Albrecht Schmidt。2015。SimpleSkin：迈向多用途智能服装。载于2015年ACM普适与泛在计算国际联合会议附属论文集及2015年ACM可穿戴计算国际研讨会论文集。241–244。[46] Satya P Singh、Madan Kumar Sharma、Aimé Lay-Ekuakille、Deepak Gangwar 和 Sukrit Gupta。2020。利用深度ConvLSTM与自注意力，通过可穿戴传感器进行人体活动解码。IEEE Sensors Journal 21，6（2020），8575–8582。[47] Takao Someya 和 Masayuki Amagai。2019。迈向新一代智能皮肤。《Nature Biotechnology》37，4（2019），382。[48] Odongo Steven Eyobu 和 Dong Seog Han。2018。基于可穿戴IMU传感器数据、采用深度LSTM神经网络的人体活动分类特征表示与数据增强。《Sensors》18，9（2018），2892。[49] Masashi Sugiyama、Matthias Krauledat 和 Klaus-Robert MÃžller。2007。通过重要性加权交叉验证实现协变量偏移适应。《机器学习研究期刊》8，5月（2007），985–1005。[50] Yushuang Tian、Xiaoli Meng、Dapeng Tao、Dongquan Liu 和 Chen Feng。2015。融合惯性测量单元与Kinect的上肢运动跟踪。《Neurocomputing》159（2015），207–218。[51] Alessandro Tognetti、Federico Lorussi、Gabriele Dalle Mura、Nicola Carbonaro、Maria Pacelli、Rita Paradiso 和 Danilo De Rossi。2014。用于动作捕捉系统的新一代可穿戴测角仪。《Journal of NeuroEngineering and Rehabilitation》11，1（2014），56。[52] Alexandra Voit 和 Stefan Schneegass。2017。FabricID：利用智能纺织品访问可穿戴设备。载于第16届移动与普适多媒体国际会议论文集。379–385。[53] Timo von Marcard、Roberto Henschel、Michael J Black、Bodo Rosenhahn 和 Gerard Pons-Moll。2018。利用惯性测量单元和移动摄像机，在野外恢复准确的三维人体姿态。载于欧洲计算机视觉会议（ECCV）论文集。601–617。[54] Xuesu Xiao 和 Shuayb Zarar。2018。用于与放置位置无关的惯性动作捕捉的机器学习。载于2018年IEEE国际机器人与自动化会议（ICRA）。IEEE，6716–6721。[55] Osman Dogan Yirmibesoglu 和 Yigit Menguc。2016。采用嵌入式惯性测量单元测量运动的混合柔性传感器。载于2016年IEEE自动化科学与工程国际会议（CASE）。IEEE，798–804。[56] Yizhai Zhang、Kuo Chen、Jingang Yi、Tao Liu 和 Quan Pan。2015。利用少量可穿戴传感器估计人体骑自行车时的全身姿态。IEEE/ASME机电一体化汇刊 21，1（2015），163–174。[57] Zhongguan Zhu、Shihui Guo、Yipeng Qin、Xiaowei Chen、Ronghui Wu、Yating Shi、Xiangyang Liu 和 廖明宏。2021。通过输出层级领域自适应，利用老化软传感器实现稳健的肘角预测。IEEE Sensors Journal 21，20（2021），22976–22984。

A 实现细节

- 我们的方法：除了部分取值范围较小的超参数外，我们先进行了粗略搜索，再按如下方式对这些超参数进行微调：将 LSTM层的数量从 $[3, 4, 5, 6, 7]$, LSTM层的单元数量从 $[64, 128, 256, 512]$, 批次大小从 $[128, 256, 512, 1024]$, η 公式 6 的 $[3000000, 4000000, 5000000, 6000000, 7000000]$, 公式 7 中的 m 从 $4.69 \times 10e - 4[9.1 \times 10e^{7}, 1 \times 10e^{8}, 1.01 \times 10e^{8}, 1.02 \times 10e^{8}]$, 公式 $r1$的，学习率从

$[1e-1, 1e-2, 1e-3, 1e-4]$，误差状态卡尔曼滤波器的预测误差与测量误差之比从 $[1.33, 2, 2.67, 3.33, 4]$。对于 r和取值范围有限的 m，我们将 r从 $[0.1, 0.15, 0.2, 0.25]$，并将 m 从 $[2, 3]$ 最后，我们将公式 η6 中的设为 5000000，将公式7 中的 m 和公式 $lambda$8 中的设为 1010000000，将公式 r1 m中的分别设为 0.25 和 2。此外，我们比较了在特征层或输出层进行迁移的结果。

• CL：该网络由三个子模块组成：(1) 一个由四个一维卷积滤波器组成的嵌入层，用于学习嵌入表示（隐藏单元数量设置为 64）；(2) 一个由一层长短期记忆网络（LSTM）组成的编码器（LSTM 单元数量设置为 256）；以及 (3) 一个由自注意力层组成的注意力模块。学习率为 0.01。超参数和网络结构均经过最优选择。

• LightGBM：参数设置可参考表 4。超参数和网络结构均经过最优选择。

• 全连接网络：该模型包含四个隐藏层，每层使用数量不同的 $[128, 256, 512, 256]$ 节点。学习率设置为 0.01。超参数和网络结构均经过最优选择。
• 随机森林：我们将超参数设置如下：最大深度为 3，估计器数量为 150，最小样本分割数为 3。超参数和网络结构均经过优化选择。

表4. LightGBM 参数。

设置	值
叶节点数	100
最大分箱数	76
最大深度	19
提升类型	gbdt
正则化 alpha	0.0001
正则化 lambda	0.0001
叶节点最小数据量	5
学习率	0.09
特征比例	0.7
装袋比例	0.7
树的数量	60