

中国科学技术大学

University of Science and Technology of China

硕士学位论文



论文题目 基于压阻型智能衣的
人体姿态重建方法

作者姓名 章东泉

学科专业 计算机应用技术

导师姓名 蔡晓辉 特任教授

完成时间 二〇二四年十月

中国科学技术大学

硕士学位论文



基于压阻型智能衣的 人体姿态重建方法

作者姓名： 章东泉

学科专业： 计算机科学与技术

导师姓名： 蔡晓辉

完成时间： 二〇二四年十月十七日

University of Science and Technology of China
A dissertation for master's degree



Human Pose Reconstruction Using a Pressure Sensing Garment

Author: Dongquan Zhang

Speciality: Computer Science and Technology

Supervisor: Xiaohui Cai

Finished time: October 17, 2024

摘要

姿态是人类活动的基础，姿态信息（人体关节的空间位置）在医疗看护、健身、虚拟现实等领域有着丰富应用。目前被最广泛使用的人体姿态重建方法是基于计算机视觉（Computer Vision, CV）的和基于惯性测量单元（Inertial Measurement Unit, IMU）的，然而上述两类方法均不适用于开放环境。

压阻型智能织物是一种测量表面压力的柔性传感器，在人类活动识别领域具有多种应用场景。使用能覆盖全身的可穿戴压阻型智能织物系统（后文中称“智能衣”）在开放环境中重建人体姿态具有以下优势：（1）比基于计算机视觉的方法受到更少的环境条件限制；（2）比基于 IMU 的方法具有更高的舒适度。然而目前基于压阻型智能织物系统的人体姿态重建工作主要集中在使用智能地毯、智能床单等部署在环境中的传感系统，暂时没有使用全身覆盖的压阻型智能衣重建人体姿态的工作。因此在使用压阻型智能衣重建人体姿态的任务中存在两个问题：（1）如何构建压阻型智能衣数据集为智能衣应用提供数据支持？（2）如何设计并实现使用压阻型智能衣数据重建人体姿态的算法？

针对问题（1），本工作中设计了一套智能衣数据采集实验方案；首先使用相机系统和压阻型智能衣系统采集受试者不同姿势下的相机 RGB 数据和智能衣压力数据，再应用已有的基于计算机视觉的人体姿态重建方法提取 RGB 数据中的姿态信息，构建“压力-姿态”数据集。针对问题（2），本工作中设计并实现了一种基于深度学习的人体姿态重建算法；首先使用基于 ResNet18 的神经网络模型预测受试者关节的旋转信息，再使用前向动力学模型重建人体姿态。主要工作内容如下：

- （1）压阻型智能衣数据集构建和分析。本工作中设计了一套智能衣数据采集方案，构建了一个包含 7 名受试者在 20 种不同姿态下的压力数据和 3D 姿态标签数据的数据集。数据集含有 150K 左右的数据帧。本工作中将智能衣采集的体表压力分布数据按照数据产生机理分为“通过接触产生的数据”和“通过运动产生的数据”两类，分析其各自特点并提出潜在应用。
- （2）基于压阻型智能衣的人体姿态重建算法。本工作中设计并实现了一种基于深度神经网络的人体姿态重建算法，并使用留一法交叉验证对此算法进行检验，此算法达到了 98.71mm 的关节位置误差。

本工作验证了使用压阻型智能衣系统进行人体姿态重建的可行性，展示了压阻型智能衣被用于在开放环境中重建人体姿态的可能性。

关键词：压阻型智能织物；人类活动识别；姿态重建；深度学习

ABSTRACT

Poses are the fundamentals of human activities and there are growing applications using pose information (positions of human joints) in healthcare, fitness and virtual reality. The most popular human pose reconstructing methods are based on computer vision (CV) and inertial measurement units (IMUs). However, such methods are not suitable in open environments.

Pressure sensing smart textile is a kind of soft sensor that measures pressure distribution on the textile surface. Reconstructing human poses in open environments using a smart textile system that covers the majority of human body (the smart garment) has the following advantages: (1) There are less environmental restrictions comparing with computer vision methods. (2) The sensing system is more comfortable than IMU-based systems. However, existing researches of reconstructing human poses using the smart textile focus on environmental sensing systems such as the smart carpet, smart bed sheet and there is no pose reconstruction method based on a full-body smart garment yet. Thus, there are 2 questions in reconstructing human poses using a textile-based pressure sensing garment: (1) How to create a smart garment dataset that supports applications such as human pose reconstruction? (2) How to design and implement a human pose reconstruction algorithm which is suitable for the smart garment data?

For Q1, a data-collecting experiment is designed. A camera system and a smart garment system are used to collect RGB data and pressure data under different poses; existing computer vision method is adopted to extract 3D human poses from RGB data to generate a 'pressure-pose' dataset. For Q2, a pose reconstruction algorithm based on deep learning is designed and implemented. A deep learning model based on ResNet18 is used to predict the rotation of the joints and a forward kinematics system is used to convert the rotation into joint positions; the reconstructed poses are then converted into camera's view. The works could be summarized as follows:

- (1) Smart garment dataset generation and analysis. A data-collecting experiment is designed and a dataset that consists of synchronized smart garment data and 3D pose labels of 7 subjects under 20 different poses is created in this study. The dataset contains around 150K data frames in total. The pressure distribution is categorized into 2 types by their causes; the patterns and potential applications are discussed.
- (2) Human pose reconstruction algorithm. A deep learning-based algorithm to re-

construct human poses using smart garment data is designed and implemented in this study. Leave-one-out cross validation is used to test the algorithm and it achieves 98.71mm of joint position error.

This work verifies the feasibility of the pressure sensing garment in reconstructing human poses and demonstrates that the pressure sensing garment has the possibility of being used in reconstructing human poses in open environments.

Key Words: Pressure Sensing Smart Textile; Human Activity Recognition; Pose Reconstruction; Deep Learning

目 录

第 1 章 绪论.....	1
1.1 研究背景.....	1
1.1.1 人体姿态重建.....	1
1.1.2 压阻型智能织物.....	2
1.2 研究现状.....	2
1.2.1 人体姿态重建.....	2
1.2.2 压阻型智能织物.....	3
1.2.3 存在的问题.....	3
1.3 论文主要工作.....	4
1.3.1 本工作中使用的方法.....	4
1.3.2 贡献点.....	6
1.4 本文的组织结构.....	6
第 2 章 相关工作	7
2.1 人体姿态重建.....	7
2.1.1 环境型姿态重建系统与方法.....	7
2.1.2 可穿戴型姿态重建系统与方法.....	8
2.1.3 总结.....	9
2.2 压阻型智能织物.....	9
2.2.1 压阻型智能织物系统.....	10
2.2.2 基于压阻型智能织物系统的人体姿态重建	10
2.2.3 总结.....	11
第 3 章 压阻型智能衣数据集	12
3.1 实验硬件设置.....	12
3.1.1 压阻阵列型智能衣.....	12
3.1.2 单目相机阵列.....	13
3.2 采集实验设计.....	13
3.3 压力数据预处理.....	15
3.3.1 位置重排.....	15
3.3.2 异常值处理.....	15
3.3.3 坏道修复.....	16
3.4 3D 人体姿态标签生成.....	17
3.4.1 人体姿态表示.....	17
3.4.2 基于 OpenPose 的 2D 关节点识别	17
3.4.3 基于线性三角化方法的 3D 标签生成.....	18

3.4.4 基于旋转分解的坐标系转换.....	20
3.4.5 基于动力学方法的标签骨架修正.....	21
3.5 压力数据可视化.....	23
3.6 压力数据产生原理与分布分析	25
3.6.1 通过接触产生的压力.....	25
3.6.2 通过运动产生的压力.....	27
3.7 本章小结.....	28
第4章 基于关节旋转预测的姿态重建算法	29
4.1 算法设计.....	29
4.1.1 模块一:ResNet18 神经网络.....	30
4.1.2 模块二:前向动力学系统.....	31
4.1.3 损失函数设计.....	32
4.2 实验评估.....	32
4.2.1 评价指标.....	32
4.2.2 Leave-One-Out 交叉验证.....	33
4.3 重建案例分析.....	36
4.4 特殊失败案例.....	40
4.4.1 智能衣设计导致的失败案例.....	40
4.4.2 数据模糊性导致的失败案例.....	41
4.5 误差时间分布分析.....	43
4.6 关于智能衣覆盖面积的消融实验	44
4.7 本章小结.....	47
第5章 总结与展望	49
5.1 工作总结.....	49
5.2 工作展望.....	49
参考文献.....	51

第1章 绪 论

1.1 研究背景

1.1.1 人体姿态重建

人体姿态是人类活动的基本元素，被应用在丰富的领域，例如人机交互^[1]、健康看护^[2]、运动科学^[3]等。人体姿态重建的目标为计算人体关节点（例如手腕、脚踝等）在 2D 或 3D 空间中的位置。目前最主流的人体姿态重建方法是基于计算机视觉的^[4-5]，通过设计神经网络模型从 RGB 图片或视频中提取人体姿态信息。图 1.1展示了使用 RGB 图片进行人体姿态重建的 OpenPose 模型。



图 1.1 基于计算机视觉的人体姿态重建方法：OpenPose^[5]。

基于计算机视觉的方法在许多场景下受到限制：足球、篮球等多人运动场景下经常产生遮挡情况，被遮挡的人体部位的重建结果一般较差；夜间锻炼时光照不足，难以获取有效的 RGB 信息；在公共场合和居家使用时存在隐私问题；使用固定摄像机的系统只能在一定范围内捕捉人体信息，无法跟随被观测人员自由移动等。后文中使用“开放环境”指代以上应用场景，其具有以下特点：空间范围大，被观测人员可以在范围内自由移动；存在遮挡、光照等环境条件限制。

为了满足在开放环境中重建人体的应用需求（例如运动员动作监测、增强现实等），可穿戴系统被开发出并用于人体姿态重建。目前主流的可穿戴人体姿态重建系统是基于惯性传感单元（Inertial Measurement Unit, IMU）的^[6]。在使用 IMU 系统时受试者需要在身上多处佩戴硬质传感器，导致 IMU 系统穿脱时间长且具有不舒适性。IMU 系统在使用前需要经过严格的校准流程，且在长时间使用后存在数据漂移现象^[7]。这些缺点给在日常生活中使用 IMU 系统带来不便。

1.1.2 压阻型智能织物

压阻型智能织物是一种测量表面压力分布的新型传感器。将具有压敏性质的导电纱线制成具备压力传感能力的纺织面料并部署在日常生活中人类经常接触的地方，可实时监测人和物体施加在织物上的压力，经过数据采集、处理和分析可实现对人类活动的初步识别^[8-9]。智能织物的应用场景如图 1.2 所示。



图 1.2 智能织物有广泛的应用场景^[10-16]

使用压阻型智能织物制作的智能衣系统不受遮挡、弱光照等环境因素干扰；比 IMU 传感器更柔软亲肤。因此压阻型智能衣系统能够回避目前基于计算机视觉和 IMU 传感器的主流方法在开放环境和日常生活中使用的局限性，具有被用于在开放环境和日常生活中进行人体姿态重建的可能。

1.2 研究现状

1.2.1 人体姿态重建

目前主流的人体姿态重建方法可被分为基于计算机视觉的和基于 IMU 的两种。基于计算机视觉的方法主要通过设计神经网络模型从 RGB 图片或视频中获得人体信息，可以被分为自顶向下^[5] (Top-down) 和自底向上^[17] (Bottom-up) 两种。自顶向下类型的方法首先在 RGB 图片或视频中对存在人体的部分进行识别和分割（分割出的部分被称为 frame，多人场景下会产生多个 frame）；再在每一个 frame 中进行关节点的识别，生成人体姿态。自底向上类型的方法首先对 RGB 图片或视频进行全局的关节点识别，再对关节点进行匹配，生成一个或多个人体姿态。基于 IMU 的方法^[6]主要通过人体多个部位绑定 IMU 传感器，记录人体运动时 IMU 传感器测量的加速度和角速度信息，再使用积分或是神经网络的方法计算人体关节点的空间位置。

1.2.2 压阻型智能织物

压阻型智能织物目前已被应用在人体姿态重建领域。基于压阻型智能织物的人体姿态重建工作目前集中在使用智能床单、智能地毯等环境型织物传感系统。压阻型智能织物采集到的数据一般为 2D 矩阵的格式（后文中称“压力图像”），基于卷积神经网络（CNN）在图像处理方面的应用背景，CNN 也被用于提取压力图像中的人体信息。目前使用压阻型智能织物系统重建人体姿态的精度低于基于计算机视觉的和基于 IMU 的方法，但压阻型智能织物提供了一种舒适地、非侵入式地在日常环境中重建人体姿态的可能。

压力数据的来源影响人体姿态重建的精度。Luo 等人^[18]等人使用足部与智能地毯接触的信息重建了人体姿态。由于大部分压力数据来源于足部与织物系统的接触，在 Luo 等人的工作中，下半身姿态的重建精度要高于上半身。在 Clever 等人^[19]使用智能床单重建人体姿态的工作中，由于受试者全身更均匀地与织物系统接触，姿态重建的误差分布在各个关节处也更加均匀。Clever 等人也在工作中指出，当腿部与智能床单缺少接触时，对腿部关节的重建精度会下降。因此，一套能够覆盖全身大部分区域的压阻型智能衣比智能袜^[20]、智能鞋^[21]、智能袖套^[22]等覆盖人体局部的织物系统具有更丰富的数据来源，有提供更高精度人体信息的可能。

目前已有的能够覆盖人体大部分的智能衣系统有 Luo 等人^[20]制造的智能背心（基于压阻型传感器）和 Onose 等人^[23]制作的全身覆盖型智能衣（基于电容传感器）。Luo 等人采集了不同姿态下智能背心上的压力分布并进行了姿态的分类；Onose 等人则对人体不同区域的压力分布进行了可视化。在本工作的调研结果中，目前并没有使用全身覆盖型智能衣进行人体姿态重建的工作。

1.2.3 存在的问题

根据压阻型智能织物领域的研究现状，使用压阻型智能衣重建人体姿态仍存在以下两个方面的问题：（1）缺少压阻型智能衣数据和对应的人体姿态数据集；（2）缺少使用压阻型智能衣数据重建人体姿态的算法。

1. 缺少数据集

目前的压阻型智能织物系统主要为环境型传感系统和覆盖人体表面少部分区域的可穿戴系统，其中被用于重建人体姿态的主要为压阻型智能床单和智能地毯系统。目前的压阻型智能织物领域不存在覆盖人体大部分区域的体表压力分布数据集。然而，数据集是深度学习算法工作的基础，算法中所使用的神经网络的训练和测试需要大量的数据样本提供支持。因此，为了使用压阻型智能衣系统所测量的体表压力分布重建人体姿态，构建一个不同姿态下的体表压力分布数据集是有必要的。

2. 缺少姿态重建方法

目前用于重建人体姿态的压力数据主要来源于智能床单系统和智能地毯系统，二者均不是可穿戴系统，其压力数据的产生机理和特征分布可能与压阻型智能衣存在较大差异；基于智能床单和智能地毯数据设计的姿态重建方法可能无法适用于压阻型智能衣数据。因此，如何设计并实现一个使用压阻型智能衣数据重建人体姿态的算法是值得研究的。

综上所述，针对使用压阻型智能衣数据重建人体姿态的任务，将考虑以下两个问题并展开工作：（1）如何构建压阻型智能衣数据集为智能衣的算法设计和应用提供支持？（2）如何设计并实现深度学习算法，使用压阻型智能衣数据重建人体姿态？

1.3 论文主要工作

基于目前已有的使用压阻型智能织物系统记录人类活动信息的研究，本工作的研究动机为：使用压阻型智能衣采集到的压力数据可能也包含人类活动信息。研究思路为：采集不同人体姿态下的智能衣压力数据作为训练样本，使用神经网络拟合压力数据和人体姿态间的映射关系。

1.3.1 本工作中使用的方法

1. 工作一：压阻型智能衣数据集构建和分析

本工作中使用的智能衣系统能够覆盖人体超过 80% 的区域，包含手臂、腿部和身体躯干，总计拥有 1952 个压力传感单元。智能衣系统由智能服装（包括上衣和裤子两部分）、智能衣驱动电路、驱动下位机和数据采集上位机组成。智能服装的设计、编织和缝纫由本实验室的梁贞完成，驱动电路、下位机和数据采集上位机由本实验的谢方婷完成。

基于已有工作中对姿态的选择，本工作中选取了 20 种不同的日常姿态（10 种站姿、10 种坐姿），设计了智能衣数据采集的实验流程。本工作中选取的姿势包含大幅度的肢体运动、自我接触和环境接触，涵盖日常生活中可能出现的一些动作和与外界的交互。基于实验室已有的压阻型智能衣系统，本工作中采集了 7 名受试者不同姿态下的体表压力分布信息。本工作中使用了由三个单目相机组成的视觉系统捕捉不同视角下的人体姿态。基于视觉的人体姿态重建模型 OpenPose 被用来识别相机画面中的关节点坐标，线性三角化算法（Direct Linear Transform, DLT）被用于生成 3D 空间坐标系下的人体姿态标签。由于智能衣为可穿戴系统，其压力数据于外部相机设置无关，本工作中使用了迭代最近邻点算法（Iterative Closest Point, ICP）将 3D 人体姿态标签调整至智能衣穿戴者的局部

坐标系下以消除外部相机的设置信息。

通过工作一，本工作构建了目前第一个含有 3D 人体姿态标签和大范围体表压力分布数据的数据集。其包含 7 名受试者共 21 人次（每人 3 人次），总计约 150K 帧数据，每帧包括 $2 \times 64 \times 32$ 双通道压力图像数据和 15×3 人体姿态标签。

本工作中对智能衣压力数据进行了定性分析，根据压力数据的产生原理将其分为以下两类：

- (1) 通过接触产生的压力。人体或者外界环境与智能衣进行接触时产生压力分布。例如掐腰时手掌在腰部产生的压力分布；二郎腿动作时腿部相互挤压产生的压力分布；坐下时背部和椅背接触产生的压力分布。此类压力分布可以体现环境特征，例如椅背的材质、形状等。
- (2) 通过运动产生的压力。当人体关节旋转时，关节会由内部挤压智能衣产生压力分布。例如手臂和腿部弯曲时，手肘和膝盖部位会产生压力分布。此外，部分肌肉绷紧时也会从内部压迫智能衣产生类似的压力分布，例如肱二头肌、肱四头肌。

综上两点，智能衣的数据包含人类活动信息，具有物理意义。通过智能衣数据推理人体的姿态是有可能的。由于智能衣较为宽松，受试者的身高、体重等差距较大，相同的人类活动在智能衣上产生压力分布的位置、大小等各不相同，并且压力分布也会受到衣服的褶皱、拧转等影响。本工作中暂没有进行额外的数据标定和算法设计对不同区域的压力进行定量的分类，而是对压力区域的识别进行定性研究。

2. 工作二：基于压阻型智能衣的人体姿态重建算法

为了拟合体表压力分布数据和 3D 人体姿态间的映射关系，本工作中设计并实现了一个使用智能衣压力的，基于人体关节旋转的人体姿态重建方法。本工作中首先使用一个由 3D 卷积层（Conv3D）和 ResNet18 网络组成的神经网络模块学习体表压力分布序列中的姿态特征，预测关节相对旋转的 6D 旋转表示（r6d）^[24]，通过 Gram-Schmidt 正交化求解得到旋转矩阵。本工作中使用了前向动力学的方法，将关节的旋转信息转换为关节的空间位置。

本工作中使用了 Leave-One-Out（LOO）交叉验证对姿态重建算法进行检验，并从不同受试者、不同关节和不同姿态角度对重建结果进行了分析；实验结果证明了使用体表压力分布重建 3D 人体姿态的可行性。本工作中对一些失败案例进行分析，发现受试者体型对体表压力分布模式具有影响，目前的姿态重建算法在重建大幅度躯干动作如弯腰时受到受试者体型影响大，会导致躯干弯曲角度的重建不准确。本工作中针对智能衣的覆盖范围进行了消融实验，在只使用上衣或裤子数据的条件下对全身姿态进行重建，其结果说明了覆盖面积的增加有助于提升姿态重建算法的精度和鲁棒性。

1.3.2 贡献点

本文工作的贡献点有:

1. 提供了目前第一个包含体表压力分布数据和 3D 人体姿态的数据集。该数据集包含 7 名受试者在 20 种不同姿态下的数据, 总计约 150K 帧, 每帧包含 $2 \times 64 \times 32$ 压力数据和 15×3 人体姿态标签。通过构建此数据集, 本工作为使用智能衣数据重建人体姿态以及智能衣的潜在应用提供了数据基础。
2. 提出并实现了一种基于关节旋转预测的, 使用体表压力分布重建 3D 人体姿态的深度学习方法, 达到了 98.71mm 的位置误差精度, 验证了使用体表压力数据重建 3D 人体姿态的可行性。展示了压阻型智能衣用于在开放环境中重建人体姿态的应用可能。

1.4 本文的组织结构

针对在开放环境中重建人体姿态的问题, 本文介绍了一种使用压阻型智能衣重建人体姿态的深度学习方法。本文的组织结构如下:

- 第一章为绪论部分, 简要描述了人体姿态重建和压阻型智能织物的研究背景, 以及目前在使用压阻型智能衣重建人体姿态遇到的问题, 最后阐述了本工作中提出的解决方法和贡献点。
- 第二章为相关工作。
- 第三章为压阻型智能衣数据集, 介绍了本工作如何使用压阻型智能衣和单目相机采集数据并构建体表压力分布数据和 3D 人体姿态数据集; 如何对原始数据进行预处理来修复数据异常情况。本章中介绍了本工作中实现的将体表压力数据映射到 3D 人体模型的可视化算法。本章也对于体表压力分布这一数据种类进行了初步探索, 解释了数据产生的机理、分布特征和人体活动之间的关系。
- 第四章为基于关节旋转预测的姿态重建方法, 介绍了本工作如何设计和实现基于 ResNet18 网络和前向动力学方法的人体姿态重建流程, 如何使用留一法交叉验证对姿态重建方法进行验证, 分析重建结果的分布特点, 对一些失败案例进行研究; 展示了压阻型智能衣具有被应用在开放环境中进行人体姿态重建的可能性。
- 第五章为总结与展望, 对本文工作进行总结, 并分析存在的不足和未来的改进方向。

第2章 相关工作

本工作的相关工作可被分为两个部分：（1）人体姿态重建和（2）压阻型智能织物。第1部分将介绍目前人体姿态重建工作的目标，不同的姿态重建系统分别具有哪些优势和劣势并指出目前在开放环境中重建人体姿态的工作存在的问题；第2部分将介绍目前的压阻型智能织物相关工作，讲述智能织物系统目前的表现形式和已有的使用压阻型智能织物数据重建人体姿态的方法，分析这些方法可如何被用于使用智能衣数据重建人体姿态的工作中。

2.1 人体姿态重建

人体姿态重建任务可以被描述为：从输入数据中提取关于人体的信息并推理人体关节点在2D或3D空间中的位置。人体姿态可以通过视觉信号、WiFi信号、惯性信号、电容和电压信号等被推测。根据系统的部署位置可将其分为环境型和可穿戴型两类。下文中将从环境型姿态重建系统和可穿戴型姿态重建系统两个方向进行人体姿态重建工作的介绍。

2.1.1 环境型姿态重建系统与方法

环境型姿态重建系统指传感设备固定在某个位置，不跟随被观测人员移动的姿态重建系统。环境型姿态重建系统中被最广泛使用的是基于计算机视觉方法的^[4-5,25]，通过使用神经网络提取RGB图片或视频中的人体姿态特征。基于计算机视觉的方法被使用的最多，人体姿态重建的精度也最高，但是对环境条件的要求也最苛刻，弱光照、遮挡等环境因素均会影响姿态重建的准确度。

Cao等人^[5]提出了OpenPose模型进行2D的人体姿态重建；该模型首先识别出图片中可能存在的关节点位置，再对关节点进行配对，生成人体姿态。基于上述模型特点，OpenPose有时存在无法识别到关节点或错误配对的情况，但是先识别关节点再进行配对的方法使其在多人场景下的姿态重建中有着较好的性能，目前被许多非视觉的姿态重建方法用于标签生成。Xu等人^[17]提出的ViTPose模型使用了另一种思路，其首先对RGB图片进行分割，划定每一个人体所在区域，再在被划定的区域中进行人体姿态的整体识别。除此之外，还有基于扩散模型^[26]、动力学^[27]等的姿态重建方法。

除了2D人体姿态，研究者们也尝试直接从RGB图片或视频中提取3D人体姿态信息，但是遇到了深度模糊性问题：2D图片只提供关节点在空间中两个坐标轴方向上的位置，缺少第三个坐标轴（一般称之为深度）方向上的信息。为了

解决计算机视觉方法中的深度模糊性问题, 研究者们提出了两种解决思路: (1) 使用多个相机组成阵列, 通过提供其他视角上的坐标信息来推算深度^[28]; Zhang 等人^[29]使用了 Transformer 从多相机视角直接生成 3D 人体姿态, 达到了 15.8mm 的精度。(2) 使用能够测量场景内深度信息的深度相机^[30]。

WiFi 是另一种被应用在人体姿态重建的环境型传感系统。通过深度学习等方法识别反射波波形中的模式来推算关节和肢体位置^[31]。Ren 等人^[32]在室内布置了 1 个 WiFi 发射器和 4 个接收器, 使用 CNN 和 LSTM 深度学习模块对接收到的反射波序列进行处理, 进行了人体姿态的重建并达到了 47mm 的精度。此类方法克服了基于计算机视觉方法对弱光照、遮挡等敏感的弱点, 但是要求环境设置较为稳定, 环境设置的改变 (例如家具摆放) 会导致反射波波形的变化从而影响姿态重建的精度。

2.1.2 可穿戴型姿态重建系统与方法

可穿戴型姿态重建系统指传感设备被部署在被观测人员身上, 可以跟随被观测人员自由移动的姿态重建系统。可穿戴型姿态重建系统中被最广泛使用的是基于惯性传感单元 (Inertia Measurement Unit, IMU) 的^[6]。系统使用时需要被观测人员在身体多处佩戴 IMU 传感器; 通过记录被观测人员运动时身体部位的加速度、角速度信息, 使用数值积分、神经网络等方法推算关节点空间位置。

由于传统的 IMU 系统在使用时要求被观测人员佩戴多个硬质的传感器, 此类系统在穿戴时较为麻烦且会影响佩戴者的正常运动, 研究者们尝试减少姿态重建系统所需求的 IMU 传感器数目^[33-35]或是使用日常电子设备中含有的 IMU 传感器 (例如耳机、手机、手环等)^[36]。Von Marcard 等人^[35]提出了 Sparse Inertial Poser (SIP), 使用常规 17 个 IMU 配置中的 6 个 (分别部署在双手手腕, 两个小腿, 背部和头部), 达到了 13.32° 的角度误差精度和 3.9cm 的距离误差精度。Molyn 等人^[36]则提出了 IMUPoser, 使用手机、手环和耳机中的 IMU 重建人体姿态, 达到了 9.7cm 的距离误差精度。

除 IMU 以外的可穿戴相机、电容传感器、压阻型传感器等也可被用于构建可穿戴型人体姿态重建系统。使用可穿戴相机的动机在于回避基于计算机视觉的姿态重建系统无法跟随被观测人员在不同场景下移动的缺点, 同时获得和 RGB 图片或视频同等丰富的信息。目前用于人体姿态重建的可穿戴相机主要被固定在被观测者的头部或是胸部。固定在头部的相机通常向下拍摄获得被观测人员全身的肢体信息, 此方法的缺点在于, 关节点的位置分布在所采集的数据集中并不均匀, 离头部越近的关节点可能的分布空间越小; 且此类相机无法捕获除了人体以外的信息, 很难被用于观察被观测人员和周围环境间的关系。为了克服头戴式相机的以上问题, Hwang 等人^[37]使用固定在胸口的广角相机来同时捕获人体

信息和环境信息,利用在公开数据集和生成数据集上训练的 ResNet 模型提取相机广角视野边缘的关节点信息,完成对 3D 人体姿态的重建,达到了 84.9mm 的精度。广角相机的缺点在于相机视角边缘处会产生严重的畸变且通常是被观测人员肢体所在区域,此外,在佩戴者进行转身等行为时,可穿戴相机拍摄的图像会出现模糊、抖动等情况,此类方法在数据处理方法和网络模型设计上仍有待研究。

使用 IMU 系统或可穿戴相机都需要被观测人员在常规穿着外佩戴额外的传感设备,为了减小其穿着负担,基于智能织物的电容传感器^[38-42]和压阻型传感器被开发出并集成到日常穿着中。Zhou 等人^[38]在夹克上集成了多个织物型电容传感器,记录不同姿态下各个通道电容值的变化情况,使用时序卷积网络对上半身的姿态进行了重建,达到了 88mm 的精度。

2.1.3 总结

本节对目前人体姿态重建工作的现状进行了简单介绍,将目前的人体姿态重建系统分为环境型系统和可穿戴型系统,分别介绍了其代表性工作和各种系统的优势和不足。

环境型系统主要分为基于计算机视觉的和基于 WiFi 的。基于计算机视觉的方法拥有最高的重建精度,但是容易受到遮挡、弱光照等环境因素的限制影响重建精度,并且具有一定的隐私问题;基于 WiFi 的方法可以回避遮挡等环境因素且没有隐私问题,但是此类系统要求环境设置相对稳定。因此,这两类环境型姿态重建系统均不适用于在开放环境中重建人体姿态。

在目前的各式可穿戴型系统中,基于惯性传感单元(IMU)的系统被使用得最广泛,其人体姿态重建精度也最高,但是基于 IMU 的系统在使用时需要被观测人员在身体各处佩戴硬质传感器,对人体活动造成影响且具有不舒适和不便性。此外还有基于可穿戴式相机和织物型电容传感器的可穿戴型人体姿态重建系统;可穿戴式相机在使用时仍具有不便性和隐私问题而电容传感器易受到环境中的电磁场干扰。因此,目前的各式可穿戴型系统在开放环境中重建人体姿态时存在一定的实用性问题。

2.2 压阻型智能织物

压阻型智能织物是一种测量表面压力分布的新型传感器。利用具有压敏性质的导电纺织材料,制成具备压力传感能力的织物传感阵列,可实时监测施加在织物上的压力分布情况。通过对采集得到的压力数据进行处理和分析,可以实现对人类行为活动的识别和监测。

2.2.1 压阻型智能织物系统

由于压阻型智能织物具有柔软、轻薄、灵活的特点，它们目前主要被集成在人们日常生活中经常接触，产生交互的位置。布置在环境中的压阻型织物系统有智能床单^[19]、智能地毯^[18,43]、智能椅^[44]等，被设计成可穿戴型系统的有智能鞋^[21,45]、智能袖套膝套^[22,46]、智能手套^[47]、智能衣^[20,48]等。通过识别织物系统表面的压力分布特征，可以对人类活动的类别（例如健身姿势）和一些人体属性（例如体重^[49]、BMI^[50]）进行推理。

Zhou 等人^[8]使用压阻型智能地毯记录了人在执行不同健身动作和同一健身动作的不同阶段时和智能地毯的接触压力，使用压力数据对健身的动作类别和阶段进行分类。类似的基于压力的人类活动识别和分类工作也被用于坐姿^[44]、卧姿^[51-53]场景中。

2.2.2 基于压阻型智能织物系统的人体姿态重建

除了对人类活动进行分类，压阻型智能织物系统还被用于记录更精细的人体活动，即人体姿态的重建。人体姿态重建的目标是推理目标关节在 2D 或 3D 空间中的位置，通常使用基于骨骼（skeleton）的人体模型。

Casas 等人^[54]使用 Hash 方法将压力图像映射到坐标系中，使用 KNN 算法中最近的 k 个邻居关节坐标的均值作为姿态重建的结果。Casas 等人也使用了 CNN 方法实现关节位置的预测，关节位置平均误差约为 80mm，优于 KNN 方法重建的结果。

Luo 等人^[18]使用压阻型智能地毯，采集单人和多人在地毯上活动时的压力信息并进行人体姿态重建。Luo 等人使用的智能地毯具有 9216 个传感点和 0.375 英寸的空间分辨率。Luo 等人使用基于 OpenPose 的方法和非线性三角化生成 3D 关节点，使用高斯滤波生成 3D 关节点分布热图作为标签。Luo 等人使用了“编码器—解码器”结构的卷积神经网络。将压力图像序列输入编码器生成初始 2D 关节点热图；解码器则将 2D 热图升维后解码为关节点的空间分布概率输出，完成 3D 人体姿态的重建。Luo 等人的工作在单人姿态重建上的关节点位置平均误差在 10cm 以内，多人场景下在 15cm 以内。

Clever 等人^[19]使用压阻型智能床单，采集不同卧姿和床的不同角度设置下的压力分布并进行人体姿态重建。Clever 等人设计了两种不同的卷积网络结构，第一种直接输出得到关节点的位置坐标，结合标签中的关节点坐标计算欧氏距离误差作为损失函数来训练网络；第二种输出根关节点位置、关节点旋转角度和肢体长度等信息生成基于动力学的人体模型，同时对关节点位置和肢体长度两项计算误差作为损失函数。两种网络分别达到了 76.56mm 和 76.72mm 的精度。

Davoodnia 等人^[55]使用了 Luo 等人^[18]的智能地毯数据集，使用 ViTPose 和

Masked auto-encoder 结构的神经网络代替 Luo 等人的 3D 卷积神经网络，提升了使用智能地毯数据重建人体姿态的精度。

表 2.1 基于压阻型智能织物的人体姿态重建工作

作者、时间↓	数据来源	人体姿态类型	模型类型	姿态重建精度
Clever 等人 ^[19] ,2018	智能床单	全身姿态	CNN	MPJPE 约 76mm
Casas 等人 ^[54] ,2019	智能床单	全身姿态	CNN	MPJPE 约 80mm
Luo 等人 ^[18] ,2021	智能地毯	全身姿态	CNN	MPJPE 约 100mm
Davoodnia 等人 ^[56] ,2021	智能床单	全身姿态	OpenPose	PCK 95%
Davoodnia 等人 ^[55] ,2023	公开数据集 ^[18]	全身姿态	ViT + MAE	PCK 95%
Zhang 等人 ^[46] ,2024	智能膝套	下半身姿态	LSTM	MPJAE 约 7 度

对目前基于压阻型智能织物系统的人体姿态重建工作的总结如表 2.1 所示。其与本工作的区别和关联可以总结如下：

- (1) 已有工作中使用的智能织物系统主要为智能地毯和智能床单。这两类织物系统为环境型传感系统，其采集的压力数据可以看作是人体在织物表面的部分投影（例如，可以从卧姿压力数据图像中肉眼观察到部分人体形状和关节位置）；本工作中使用的压阻型智能衣为可穿戴型系统，其采集的压力数据为穿戴者体表的压力分布，具有 3 维的空间特征。因此，使用神经网络直接回归得到关节坐标的方法并不一定适用于使用智能衣数据的人体姿态重建。
- (2) 已有工作中所使用的神经网络模型主要为简单的数个卷积层或是现有的神经网络结构（例如 ResNet18），这是由于压阻型智能织物数据（单通道图像）的内容丰富度相较于 RGB 图片和视频（3 通道图像和图像序列）更低；网络的预测目标一般为关节空间坐标，维度在数十维，任务难度较为简单（相比较下体态的预测工作需要预测 6000 个以上的参数）。出于以上考虑，使用复杂的神经网络可能导致过拟合。本工作中借鉴思想，使用现有的 ResNet18 结构作为神经网络模型的主体。

2.2.3 总结

本节对目前的压阻型智能织物系统进行了介绍，分别从织物系统的形态和应用角度对研究现状进行了描述。压阻型智能织物目前已经被部署在床单、地毯等经常与人接触的环境中，也被制作成可穿戴的织物配件如手套、袖套等。已有的使用压阻型智能织物系统重建人体姿态的工作主要集中在卧床姿态重建，使用的姿态重建方法均为较简单的卷积神经网络结构或时序神经网络结构，关节点平均位置误差在 80mm 左右。暂时没有使用能够覆盖身体大部分区域的压阻型智能衣重建人体姿态的工作。通过对已有工作的分析，本工作中认为目前被普遍使用的将压力数据直接回归到关节坐标的方法可能不适用于智能衣压力数据。通过借鉴已有思路，本工作将考虑通过预测关节旋转来重建人体姿态。

第3章 压阻型智能衣数据集

基于压阻型智能织物领域的研究现状，现缺少基于智能衣的压力数据集为姿态重建工作和其他潜在应用提供数据支持。因此本工作中将设计智能衣数据采集实验并构建智能衣“压力-姿态”数据集。本章将介绍以下内容：（1）本工作中构建压阻型智能衣数据集的方法，包括数据采集实验的硬件设置、姿态和实验流程设计、数据采集过程和标签生成过程；（2）本工作中设计并实现的将2D压力矩阵映射到3D人体模型上的可视化系统，初步解决了2D压力矩阵无法直观体现体表压力分布的问题；（3）本工作中对智能衣压力数据产生机理的定性分析，将智能衣压力数据分为由“接触”产生的和由“运动”产生的。

3.1 实验硬件设置

3.1.1 压阻阵列型智能衣

本工作中使用了一套全身覆盖的压阻型智能衣测量受试者不同姿态下的体表压力分布。智能衣的传感区域由横向传感条纹（图3.1中所示灰色条纹，后文中称“横条”）和纵向传感条纹（位于智能衣服装内侧，后文中称“竖条”）组成。横条和竖条由具有压敏性质的导电材料构成，其交叉点即为一个压力采样点。智能衣驱动电路周期性对压力采样点施加电压，通过测量该压力采样点分压计算该采样点受到的压力大小。本工作中使用的压力数据为电压信号数值化的结果，并非真实的压力（N）或压强（Pa）值。

智能衣覆盖人体表面超过80%的区域，共包含1952个压力采样点。智能衣及受试者穿戴效果如图3.1所示。传感区域包括左右手臂、左右腿和身体躯干，不包括手掌、脚部、头部和肩膀，约 $2.5 \times 2.5\text{cm}^2$ 范围内包含一个压力采样点。

下位机被用于驱动智能衣电路进行10Hz的压力数据采集。智能衣上衣和裤子分别由一块STM32驱动板驱动，采样板之间使用连接线连接，使得智能衣上衣和裤子同步采集压力数据。本工作中使用蓝牙连接将采集到的压力数据传输到上位机电脑中存储。本工作中使用的智能衣采样频率小于单目相机采样频率，本工作对智能衣和相机的起始时间戳进行同步，通过复用智能衣数据使其与相机采样对齐。压阻型智能衣制作过程中的织物设计、编织和缝纫是由本实验室的梁贞完成的，驱动电路设计和电路板制作是由本实验室的谢方婷完成的，本文作者参与了排线制作。



图 3.1 压阻型智能衣与着装效果图

3.1.2 单目相机阵列

本工作中使用了由 3 个单目相机组成的相机阵列，从左、中、右三个视角对受试者 RGB 数据进行同步采集。RGB 数据同步采集系统是由本实验室的赵明杰完成的。三个单目相机的位置为均匀分布，相机与受试者之间的相对位置和受试者的活动范围如图 3.2 所示。RGB 数据的采集频率被设置为 15Hz。



图 3.2 单目相机位置与受试者活动范围展示

3.2 采集实验设计

本工作根据已有的姿态重建工作中使用的姿态，选择了共 20 种动作（站姿、坐姿各 10 种）并招募了 7 名受试者（subject）。每次实验时受试者按顺序执行 20 种动作，每种动作持续约 20 秒；每名受试者进行 3 次实验。为了尽可能地模拟日常环境，受试者被允许以他们最舒服的方式执行动作，不进行严格的关节点位置要求。本工作中详细的姿态选择与选择原因如图 3.3 与表 3.1 所示。每次数据采集实验全长约 20-30 分钟，本工作中截取包含受试者执行动作的帧为有效帧，

删除受试者在姿态间切换时的视频数据。

本工作中在选择站姿时考虑了身体关节各个自由度上的运动，例如躯干的前倾（弯腰摸脚趾）、后仰（单手与双手扶腰）、左右侧摆（侧向伸展）；肩膀运动（侧向伸展、弯腰摸脚趾、手臂平举）；手肘弯曲（转体、单手与双手扶腰、单手与双手掐腰）；胯部运动（前弓步、侧弓步）；膝盖运动（前弓步、原地行走）。本工作中在选择坐姿时尽可能覆盖日常生活中出现的坐姿以及在椅子上可能使用的配件（例如腰垫），并使用了3种不同的椅子（硬质椅背、软质椅背和无椅背）用于丰富数据分布。



图 3.3 本工作中使用的 20 种不同姿态

表 3.1 本工作中使用的姿态与选择原因

姿态类别	姿态名称	选择原因
坐姿	正坐，手放在膝盖上	日常坐姿
	二郎腿坐，左腿在上	日常坐姿
	二郎腿坐，右腿在上	日常坐姿
	侧坐，左侧朝向椅背	日常坐姿
	侧坐，右侧朝向椅背	日常坐姿
	正坐，腰部垫枕头	久坐工作者有使用腰垫的习惯
	双手抱胸坐	日常坐姿
	抱腿坐	居家常见坐姿
	正坐，手放在扶手上	日常坐姿
	小腿交叉坐	日常坐姿
站姿	转体	典型拉伸动作
	侧向伸展	典型拉伸动作
	前弓步	典型拉伸动作
	侧弓步	典型拉伸动作
	单手与双手扶腰	久坐工作者有拉伸腰部习惯
	弯腰摸脚趾	日常动作
	深蹲起	日常动作
	原地行走	日常动作
	手臂平举	日常动作
	单手与双手掐腰	日常动作

3.3 压力数据预处理

原始智能衣数据为 2D 压力矩阵形式，分为 56×40 上衣压力数据和 64×32 裤子压力数据两部分。本工作中对压力数据进行了位置重排、异常值处理和坏道修复三步处理。位置重排步骤还原压力数据的空间位置；异常值处理步骤消除高数值短路点；坏道修复步骤修复可能存在的断路点，增强压力数据的连续性。

3.3.1 位置重排

原始智能衣数据中数据点的位置与智能衣驱动电路设计有关，不能体现数据点在人体表面的空间位置。如图 3.4（左）所示，躯干部分和臀部压力数据均被分为不相邻的两个区域。为了还原数据点在人体表面的位置，本工作中设计映射方法对压力数据进行了重排。 56×40 上衣压力数据和 64×32 裤子压力数据被转换为 $2 \times 64 \times 32$ 的双通道压力图像，两个通道分别代表从人体正面和背面观察时体表的压力分布。2D 矩阵的重新排布结果见图 3.4（右）所示。




图 3.4 压力图像重排。（左）原始智能衣压力数据；数据点位置由驱动电路结构决定。（右）重排后的智能衣压力数据；数据点位置由空间位置决定。

3.3.2 异常值处理

智能衣数据会受到短路影响，此时压力数据上出现数值过高的噪点。本工作中通过设置阈值控制压力数据的范围，截断过高的压力数据点。图 3.5 展示了本工作中对受试者 5 三次实验数据的分布统计，绝大部分压力数据的大小落在 $[0, 200)$ 。本工作中使用了两个阈值：第一个阈值为 512，压力值大小在 $[0, 512)$ 间的数据点保留原数值大小；第二个阈值为 1024，压力值大小在 $[512, 1024)$ 间的数据点的数据值被设置为 512；压力值大小超过 1024 的数据点被视作短路，数据值被设置为 0。图 3.6（b）展示了去除短路噪点对压力图像的改善情况。




图 3.5 数据点数值大小统计。横坐标为压力数据值，纵坐标为对应该压力值的数据点个数。

3.3.3 坏道修复

智能衣数据会受到断路影响，体现为压力数据上某一行或某一列缺少数据值。本工作中使用了高斯滤波的方法对压力数据进行平滑，使用邻近的压力数据对出现断路的数据点进行插值拟合，增强压力数据分布的连续性和平滑性。本工作中使用的高斯核大小为 3×3 ，平滑时使用高斯核内 9 个数据点的均值代替中心点的数据值。图 3.6 (c) 展示了填补断路数据对压力图像的改善情况。




图 3.6 重排后的压力图像预处理流程。(a) 包含短路点和坏道的压力图像；(b) 设置阈值截断短路点后的压力图像；(c) 使用高斯滤波平滑后的压力图像。

3.4 3D 人体姿态标签生成

为了验证智能衣被用于姿态重建的可行性,还需要 3D 人体姿态标签用于深度学习网络的训练和评估。本工作中使用了基于视觉的深度学习方法 OpenPose 在相机视角中分别识别 2D 人体骨架并综合 3 个相机视角生成 3D 人体标签。通过上述生成的 3D 人体标签位于相机的全局坐标系中,包含外部相机设置信息。然而智能衣为可穿戴系统,与外部相机独立。本工作中使用了基于特征值分解的方法将 3D 人体标签转换至智能衣穿戴者的局部坐标系中。

3.4.1 人体姿态表示

人体模型常被用于表示人体姿态,其中基于骨架的模型(后文中称“人体骨架”)由关节点和肢体构成,更适合被用于姿态重建工作。人体骨架的拓扑结构为单向树,树状图中的节点代表关节点,边代表肢体,树的根被称为根关节点。人体姿态的参数一般有“坐标参数”和“旋转参数”两种,分别可以唯一描述一个姿态。默认参数下的人体姿态被称为“姿态模板”。

坐标参数为各个关节点的空间位置。使用关节点坐标表示人体姿态最方便快捷、最直观,但是坐标表示只使用 2D 或 3D 空间坐标且坐标分量之间没有约束,实际应用时很难对关节点位置进行规范,存在产生不合理姿态的可能。旋转参数记录了使关节点从姿态模板位置运动到目标姿态位置的旋转矩阵,分为全局旋转和相对旋转两种。使用全局旋转时,一个关节点的位置只与自身旋转矩阵有关;使用相对旋转时,关节点的位置会受到从根关节点到当前关节点路径上所有关节点运动的影响,更加考虑现实中的人体运动:例如摆动大臂时小臂会跟随摆动,但是摆动小臂时大臂不会随之运动。

本工作中的人体骨架包含 15 个关节点,臀部中央关节点(mid_hip)为根关节点,肢体被定义为由父关节点指向子关节点。人体骨架配置如表 3.2 所示。

3.4.2 基于 OpenPose 的 2D 关节点识别

本工作中使用了 OpenPose 模型识别 RGB 图像中的 2D 人体骨架如图 3.7 所示。OpenPose 识别图像中的关节点并返回 x 轴坐标、 y 轴坐标和置信度三个返回值($x, y, confidence$)。 x 、 y 坐标为基本的关节点信息,置信度将作为权重用于 2D 关节点到 3D 关节点的生成过程。

OpenPose 有时会出现无法识别关节点的情况,此时 OpenPose 返回一个关节点坐标为 (0,0) 置信度为 0 的空关节点用于补全人体骨架。在此情况发生时,本工作中选择复用上一帧的识别结果来填充空关节点。在进行 2D 关节点预处理时,只需保证第一帧数据返回具有意义的关节点 2D 坐标和置信度数值即可保证处理后的 2D 关节点中不存在空关节点。

表 3.2 本工作中使用的人体骨架配置

关节点中文名称	关节点英文名称	父关节点	肢体中文名称	肢体英文名称
臀部中央	mid_hip	无	无	无
脖子	neck	胯部中央	躯干	body
鼻子	nose	脖子	脖颈	neck
左肩膀	left_shoulder	脖子	左肩	left_shoulder
右肩膀	right_shoulder	脖子	右肩	right_shoulder
左手肘	left_elbow	左肩膀	左大臂	left_main_arm
右手肘	right_elbow	右肩膀	右大臂	right_main_arm
左手腕	left_wrist	左手肘	左小臂	left_fore_arm
右手腕	right_wrist	右手肘	右小臂	right_fore_arm
左臀	left_hip	胯部中央	左胯	left_hip
右臀	right_hip	胯部中央	右胯	right_hip
左膝盖	left_knee	左胯	左大腿	left_thigh
右膝盖	right_knee	右胯	右大腿	right_thigh
左脚踝	left_ankle	左膝盖	左小腿	left_crus
右脚踝	right_ankle	右膝盖	右小腿	right_crus



图 3.7 使用 OpenPose 识别 2D 人体姿态

3.4.3 基于线性三角化方法的 3D 标签生成

将多个视角下的 2D 姿态转换为 3D 姿态需要使用相机的外部参数（后文中简称“外参”）和内部参数（后文中简称“内参”）。外参将坐标从 3D 世界坐标系转换进 3D 相机坐标系；内参将坐标从 3D 相机坐标系转换进 2D 像素坐标系。本工作中使用 MatLab 软件中提供的 Camera Calibrator 模块，通过识别特制的标定板在 RGB 图像中的位置计算相机的内参和外参。下文中将相机 i ($i = 0, 1, 2$) 的内参记作 $\mathbf{CP}_i$ ，相机 i, j ($i, j = 0, 1, 2$) 之间的外参记作 $\mathbf{EX}_{ij}$ 。

获得相机外参和内参后，本工作中使用线性三角化方法（Direct Linear Transform, DLT）计算每个关节点在世界坐标系下的 3D 坐标。本工作中使用 0 号相机的视角作为主视角，三角化得到的 3D 姿态均在 0 号相机的视角下进行表达。本工作中首先将三个单目相机两两配对，使用算法 3.1 所示的双相机三角化算法生成三个 3D 人体姿态。“0 号-1 号”双相机三角化过程和“0 号-2 号”双相机三角化过程有 0 号相机参与，三角化得到的 3D 姿态即在 0 号相机的视角下；“1 号-2 号”双相机三角化过程没有 0 号相机参与，本工作中首先在 1 号相机的视角

下表达该 3D 姿态，再使用 0 号相机与 1 号相机的外参 $\mathbf{EX}_{01}$ 将 3D 姿态转移到 0 号相机的相机坐标系中。三个在 0 号相机视角下表达的姿态的加权平均结果为最终的三相机三角化结果。基于 DLT 算法的三相机三角化流程图如图 3.8 所示。

算法 3.1 基于 DLT 的双相机三角化算法

输入：对一个关节点 j 进行三角化，0 号相机视角中的 2D 坐标 j_0 ，1 号相机视角中的 2D 坐标 j_1 ，0 号相机内参 $\mathbf{CP}_0$ ，1 号相机内参 $\mathbf{CP}_1$ ，0 号相机与 1 号相机之间外参 $\mathbf{EX}_{01}$

输出：关节点 j 在 0 号相机中的 3D 坐标

1 $\mathbf{M}_0 \leftarrow \mathbf{CP}_0 \cdot \mathbf{I}_4[0:3,:]$

2 $\mathbf{M}_1 \leftarrow \mathbf{CP}_1 \cdot \mathbf{EX}_{01}[0:3,:]$

3 $a_0 \leftarrow j_0[0] \cdot \mathbf{M}_0[2,:] - \mathbf{M}_0[0,:]$

4 $a_1 \leftarrow j_0[1] \cdot \mathbf{M}_0[2,:] - \mathbf{M}_0[1,:]$

5 $a_2 \leftarrow j_1[0] \cdot \mathbf{M}_1[2,:] - \mathbf{M}_1[0,:]$

6 $a_3 \leftarrow j_1[1] \cdot \mathbf{M}_1[2,:] - \mathbf{M}_1[1,:]$

7 $\mathbf{A} \leftarrow (a_0 \ a_1 \ a_2 \ a_3)$

8 $\mathbf{U}, \sigma, \mathbf{V}^T \leftarrow \text{SVD}(\mathbf{A})$

9 $p \leftarrow \mathbf{V}[:,3]$

10 $p \leftarrow \frac{p}{p[3]}$

11 return p

/* 特征值分解, SVD */

The diagram illustrates the triangulation process flowchart based on the DLT algorithm. It shows three rows of 2D camera poses (0, 1, and 2 cameras) being triangulated pairwise to produce 3D poses. The 0-1 triangulation is scaled by $\mathbf{I}_3$, the 0-2 triangulation is scaled by $\mathbf{I}_3$, and the 1-2 triangulation is scaled by $\mathbf{EX}_{01}$. Finally, the three 3D poses are weighted and averaged to produce the final 3D pose.

图 3.8 基于 DLT 算法的三相机三角化流程。首先使用双相机三角化算法生成 3 个 3D 姿态，再计算加权平均。

使用上述方法生成的 3D 人体姿态标签存在两个问题：（1）标签位于外部相机所定义的全局坐标系中，而智能衣为可穿戴系统，其采集的数据与外部相机独立；因此，3D 人体姿态标签应该被转换至智能衣穿戴者的局部坐标系中；（2）由于 DLT 算法的误差，3D 人体姿态标签的肢体长度不稳定，会给重建结果引入额外误差；因此，需要将 3D 人体姿态标签的肢体长度设置为固定值。

19

中国知网 <https://www.cnki.net>

3.4.4 基于旋转分解的坐标系转换

DLT 算法生成的 3D 人体姿态标签在外部相机定义的全局坐标系下得到表达；然而智能衣压力数据与外部相机的设置独立。因此，需要将 3D 人体姿态标签转换进智能衣穿戴者的局部坐标系中。

首先指出，在本工作的实验设置中，外部相机的全局坐标系和穿戴者的局部坐标系之间的区别为绕竖直方向（z 轴）的旋转，如图 3.9 所示。将 3D 人体姿态标签转换进穿戴者的局部坐标系只需要计算两个坐标系间的旋转矩阵，再将 3D 人体姿态标签逆向旋转即可。本工作中，关节点 mid_hip 的坐标始终被设置为坐标原点，由于 neck, left_hip 和 right_hip 三个关节点与 mid_hip 直接相连，四个关节点均位于人体躯干且活动范围较小，本工作中使用 neck, left_hip 和 right_hip 关节点确定局部坐标系的方向，因此只需要计算将上述三个关节点从姿态模板中位置旋转至 3D 人体姿态标签中位置的旋转矩阵，将其绕 z 轴方向的旋转移除。




图 3.9 相机坐标系和穿戴者坐标系下的 3D 人体姿态。黑色坐标轴代表穿戴者坐标系中坐标轴的方向。

本工作中使用了基于特征值分解的迭代最近邻算法（Iterative Closest Point, ICP）计算上述旋转矩阵。ICP 算法通常被用于将多个点云数据集对齐到同一坐标系下，通过对点云进行旋转和平移变化，使得对应点间的距离误差均值最小。设存在两个点云 P_s （待变换点云，source）和 P_t （目标点云，target），则 ICP 算法的目标为找到旋转变换 R^* 和平移变换 t^* 使得目标函数 $\mathcal{L}_{ICP}$ 最小；最小化此目标函数的解可使用特征值分解（Singular Value Decomposition, SVD）的方法求得。本工作中的人体姿态的根关节点均被设置为坐标原点，故只需要求解旋转变换 R^* （本工作中记为 $\mathbf{R}_{mid_hip}$ ，即根关节点全局旋转矩阵）。ICP 算法如算法 3.2 所示。

$$\mathcal{L}_{ICP} = \frac{1}{|P_s|} \sum_{i=1}^{|P_s|} \|p_t^i - (R^* \cdot p_s^i + t^*)\|^2 \quad (3.1)$$

获得全局旋转矩阵 $\mathbf{R}_{mid_hip}$ 后，需要将其按序分解到 z,y,x 三个方向： $\mathbf{R}_{mid_hip} = \mathbf{R}_z \mathbf{R}_y \mathbf{R}_x$ 。设 $\{q_k\} (k = 1, 2, \dots, 15)$ 为相机坐标系下 3D 姿态标签中关

算法 3.2 基于特征值分解的 ICP 算法

输入：共 N 个关节点，姿态模板 $P = [p_1, \dots, p_N]$ ，目标姿态 $Q = [q_1, \dots, q_N]$

输出：根节点全局旋转矩阵 $R_{\text{mid_hip}}$

```

1 Initial  $P' \leftarrow [p_{\text{left\_hip}}, p_{\text{right\_hip}}, p_{\text{neck}}]$ ,  $Q' \leftarrow [q_{\text{left\_hip}}, q_{\text{right\_hip}}, q_{\text{neck}}]$ ;
2  $P' \leftarrow P' - p_{\text{mid\_hip}}$ ;
3  $Q' \leftarrow Q' - q_{\text{mid\_hip}}$ ;
4  $H \leftarrow \sum_{i=1,2,3} Q'[i] \cdot P'[i]^T$ ;
5  $U, \text{sigma}, V^T \leftarrow \text{SVD}(H)$  /* SVD, 特征值分解 */;
6  $R_{\text{mid\_hip}} = V \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & \det(VU^T) \end{pmatrix} U^T$ ;
7 return  $R_{\text{mid\_hip}}$ 

```

节点的坐标，则 $\{R_z^{-1}q_k\} (k = 1, 2, \dots, 15)$ 为穿戴者坐标系下 3D 姿态标签中关节点的坐标。本工作中保留了绕 x 轴和绕 y 轴方向的旋转信息，原因为绕 x 轴方向的旋转出现在弯腰动作中，绕 y 轴方向的旋转出现在躯干侧摆动作中，绕上述两个方向的旋转均可以体现在智能衣的数据上，故将其作为标签信息的一部分。

3.4.5 基于动力学方法的标签骨架修正

通过三角化方法直接生成的 3D 人体骨架具有肢体长度不稳定的问题，图 3.10 展示了受试者 5 第一次实验在执行不同姿态时“躯干”肢体长度随时间的变化情况。标签肢体长度的不稳定性会引入额外的误差。为了消除肢体长度带来的影响，本工作中提取了初始 3D 人体姿态中的关节点旋转角信息，结合稳定的人体骨架生成新的 3D 姿态标签。




图 3.10 通过三角化方法生成的 3D 人体骨架存在肢体长度不稳定的情况。蓝色折线为“躯干”长度随时间的变化，红色为“躯干”长度的平均值。

本工作中参考了 HybrIK 工作^[27]中基于 Rodrigues 公式的反向动力学方法 (Inverse Kinematics, IK) 计算 3D 人体姿态中的关节旋转角信息。Rodrigues 公式与反向动力学算法如算法 3.3 与算法 3.4 所示。反向动力学算法中使用的初始值 $\mathbf{R}_{\text{mid_hip}}$ 即为 3.4.4 节中计算的根关节全局旋转矩阵。

算法 3.3 基于 Rodrigues 公式的旋转矩阵计算

输入：旋转前向量 $\text{vec}_{\text{before}}$ ，旋转后向量 $\text{vec}_{\text{after}}$
 输出：旋转矩阵 $\mathbf{R}$

```

1  $\text{axis} \leftarrow \text{vec}_{\text{before}} \times \text{vec}_{\text{after}}$ ; /* 使用旋转前后向量的外积作为旋转轴 */
2  $\text{rotate\_angle} \leftarrow \arccos\left(\frac{\text{vec}_{\text{before}} \cdot \text{vec}_{\text{after}}}{\|\text{vec}_{\text{before}}\| \cdot \|\text{vec}_{\text{after}}\|}\right)$ ;
3  $\text{axis} \leftarrow \text{rotate\_angle} \cdot \frac{\text{axis}}{\|\text{axis}\|}$ ; /* 使用旋转角作为旋转轴模长 */
4  $[\text{axis}]_{\times} \leftarrow \begin{pmatrix} 0 & -\text{axis}[3] & \text{axis}[2] \\ \text{axis}[3] & 0 & -\text{axis}[1] \\ -\text{axis}[2] & \text{axis}[1] & 0 \end{pmatrix}$ ; /* 计算旋转轴向量的斜对称矩阵 */
5  $\mathbf{R} \leftarrow \mathbf{I}_3 + \sin(\text{rotate\_angle}) \cdot [\text{axis}]_{\times} + (1 - \cos(\text{rotate\_angle}))[\text{axis}]_{\times}^2$ ; /* 计算沿该旋转轴的旋转矩阵 */
6 return  $\mathbf{R}$ 

```

算法 3.4 反向动力学算法^[27]

输入：共 N 个关节，姿态模板 $\mathcal{P} = [p_1, \dots, p_N]$ ，目标姿态 $\mathcal{Q} = [q_1, \dots, q_N]$ ， $\text{parent}[i]$ 表示关节 i 的父节点
 输出：关节全局旋转矩阵 $\mathbf{R}_{\text{global}} = [\mathbf{R}_{\text{global},1}, \dots, \mathbf{R}_{\text{global},N}]$ ，相对旋转矩阵 $\mathbf{R}_{\text{local}} = [\mathbf{R}_{\text{local},1}, \dots, \mathbf{R}_{\text{local},N}]$

```

1 Initial  $\mathbf{R}_{\text{global}} \leftarrow [\mathbf{R}_{\text{mid\_hip}}]$ ,  $\mathbf{R}_{\text{local}} \leftarrow [\mathbf{R}_{\text{mid\_hip}}]$ 
2 for  $i \leftarrow 2$  to  $N$  do
3    $\text{joint}_i \leftarrow q_i$ ;
4    $\text{parent\_joint}_i \leftarrow \text{parent}[i]$ ;
5    $\text{template}_i \leftarrow p_i$ ;
6    $\text{parent\_template}_i \leftarrow \text{parent}[i]$ ;
7    $\text{pose} \leftarrow \text{joint}_i - \text{parent\_joint}_i$ ; /* 计算目标姿态上的肢体向量 */
8    $\text{template} \leftarrow \text{template}_i - \text{parent\_template}_i$ ; /* 计算姿态模板上的肢体向量 */
9    $\text{pose} \leftarrow \mathbf{R}_{\text{global},\text{parent}[i]}^{-1} \cdot \text{pose}^T$ ; /* 移除受父关节影响的旋转分量 */
10   $\mathbf{R}_{\text{local}} \leftarrow \text{append}(\mathbf{R}_{\text{local}}, \text{Rodrigues}(\text{template}, \text{pose}))$ ; /* 计算当前关节相对旋转矩阵 */
11   $\mathbf{R}_{\text{global}} \leftarrow \text{append}(\mathbf{R}_{\text{global}}, \mathbf{R}_{\text{global},\text{parent}[i]} \cdot \text{Rodrigues}(\text{template}, \text{pose}))$ ; /* 计算当前关节全局旋转矩阵 */
12 end
13 return  $\mathbf{R}_{\text{global}} \cdot \mathbf{R}_{\text{local}}$ 

```

得到关节旋转信息后，本工作中使用稳定的姿态模板重新生成 3D 姿态标签。各肢体长度采用了每名受试者 3 次实验中长度的平均值，每名受试者各自拥有独立的姿态模板。姿态的重新生成过程参考了 HybrIK 工作中的前向动力学算法，如算法 3.5 所示。前向动力学算法的计算结果即为本工作的数据集中使用的 3D 人体姿态标签。数据集中的标签被统一在智能衣穿戴者的局部坐标系下，且具有稳定的肢体长度。

算法 3.5 前向动力学算法^[27]

输入：共 N 个关节点，姿态模板 $\mathcal{P} = [p_1, \dots, p_N]$ ，相对旋转矩阵 $\mathbf{R}_{local} = [\mathbf{R}_{local,1}, \dots, \mathbf{R}_{local,N}]$ ， $parent[i]$ 表示关节点 i 的父节点

输出：目标姿态 $\mathcal{Q} = [q_1, \dots, q_N]$

```

1 Initial  $\mathcal{R}_{global} \leftarrow [\mathbf{R}_{local,1}]$ ,  $\mathcal{Q} = [\mathbf{R}_{local,1} \cdot p_1]$ ; /* 根关节点的全局旋转和相对旋转一致 */
2 for  $i \leftarrow 2$  to  $N$  do
3    $\mathcal{R}_{global} \leftarrow \text{append}(\mathcal{R}_{global}, \mathbf{R}_{global,parent[i]} \cdot \mathbf{R}_{local,i})$ ; /* 使用父关节点的全局旋转和当前关节点的相对旋转计算当前关节点的全局旋转 */
4    $template \leftarrow p_i - p_{parent[i]}$ ; /* 设置肢体向量 */
5    $\mathcal{Q} \leftarrow \text{append}(\mathcal{Q}, \mathbf{R}_{global,i} \cdot template + \mathcal{Q}_{parent[i]}$ ; /* 计算关节点坐标 */
6 end
7 return  $\mathcal{Q}$ 

```

3.5 压力数据可视化

3.3节展示了压阻型智能衣数据的 2D 矩阵形式，在预处理时可以使用类似图像处理的方式对压力数据进行滤波、插值等操作，但是 2D 矩阵形式的压力数据对肉眼观察并不友好，无法直观地获得压力数据与体表位置之间的关系。为了解决这一问题，本工作中设计并实现了一个将 2D 压力数据矩阵映射到基于体积的 3D 人体模型上的可视化算法。

本工作中使用了 OBJ 格式的人体模型，该模型使用顶点 (vertex) 和面 (surface) 组成人体形状。可视化算法的核心思想可以被描述为：对于每一个顶点集 $\mathcal{V}$ 中的顶点 v ，找到距离该顶点最近的压力采样点，将压力值 p 赋给顶点 v 。完成压力数据赋值后，使用 Visualization Toolkit (VTK) 的插值渲染方法对每一个面进行染色，完成数据可视化过程。

为了建立模型顶点和压力采样点之间的映射关系，本工作中将人体模型分为 5 个部分（躯干、左手臂、右手臂、左腿、右腿），将每个部分抽象为圆柱体并各自建立局部圆柱坐标系。以圆柱坐标系为媒介，模型顶点和压力采样点之间的映射关系可以由两部分组成：模型顶点在圆柱坐标系上的坐标和压力采样点在圆柱坐标系上的坐标。图 3.11 展示了求解顶点在圆柱坐标系上坐标的方法。圆柱坐标 (ρ, θ, z) 由径向坐标 ρ （沿径向向量向外的距离）、周向坐标 θ （顶点向量和径向向量之间的夹角）和轴向坐标 z （顶点在轴向上的高度）三部分组成。由于智能衣测量的范围可以被认为是圆柱表面，本工作中不考虑径向坐标 ρ 。

按照智能衣横向和纵向传感条的数量将圆柱体沿轴向和周向均匀划分即可得到采样点坐标 (ϕ, h) 。记 M_i 和 N_i 分别为圆柱体 i 上横向传感条和纵向传感条的数目，圆柱体 i 的高度为 H_i ，则每一个压力采样点覆盖圆柱侧表面的周向范围为 $\frac{2\pi}{M_i}$ ，覆盖轴向的范围为 $\frac{H_i}{N_i}$ 。采样点 (i, ϕ, h) 测量的压力值应该被映射到所




图 3.11 可视化算法核心：计算顶点在柱坐标系上的坐标。(a) 以躯干坐标系为例，计算顶点在坐标系上柱坐标的方法；(b) 本工作中将人体抽象为 5 个圆柱的方法。为代码实现方便，每个柱坐标系的径向坐标轴方向并不一致。

有满足以下条件的模型顶点 (i, θ, z) ：

$$\begin{cases} \theta \in [\phi - \frac{\pi}{M_i}, \phi + \frac{\pi}{M_i}] \\ z \in [h - \frac{H_i}{2N_i}, h + \frac{H_i}{2N_i}] \end{cases} \quad (3.2)$$

H_i 与可视化系统中使用的人体模型有关，为固定值。通过维护 M_i 和 N_i 的值，将其记录为文件可以保证可视化系统的可扩展性，只需要修改配置文件中横纵条在 2D 压力矩阵上的顺序即可将此可视化算法移植到其他覆盖人体表面的智能织物系统上。配置文件参数如图 3.12 所示。在本工作中使用的智能衣外，本可视化系统已被移植用于本实验室其他的可穿戴型智能织物系统，验证了其可扩展性。本可视化系统的 demo 已于 Github 上开源：

<https://github.com/PhilipZhang0907/smart-garment>。

```
"left_arm":{
  "horizontal": [15, 14, 13, 12, 11, 10, 9, 8, 7, 6, 5, 4, 3, 2, 1, 0, 55, 54, 53, 52],
  "vertical": [0, 1, 2, 3, 4, 5, 6, 7]
},
"right_arm":{
  "horizontal": [47, 46, 45, 44, 43, 42, 41, 40, 39, 38, 37, 36, 35, 34, 33, 32, 55, 54, 53, 52],
  "vertical": [16, 17, 18, 19, 20, 21, 22, 23]
},
```

图 3.12 用于提高可视化系统可扩展性的配置文件。'horizontal' 键记录了横条在 2D 压力矩阵上的顺序，'vertical' 键记录了纵条在 2D 压力矩阵上的顺序

通过计算以上映射关系，本工作将 2D 压力矩阵映射到了 3D 人体模型上，增强了体表压力分布数据的直观性，可视化结果如图 3.13 所示。




图 3.13 将 2D 压力矩阵映射到 3D 人体模型。(a) 原始 2D 压力矩阵，灰色区域为实际上不存在的采样点；(b) 压力矩阵区块在人体对应位置；(c) 映射压力值到 3D 人体模型。

3.6 压力数据产生原理与分布分析

压阻型智能衣系统采集的数据可能包含人类活动的物理信息。基于此假设本工作中对智能衣压力数据的产生机理进行了定性研究，将其分为（1）通过接触产生的压力和（2）通过运动产生的压力两类。

3.6.1 通过接触产生的压力

第一类为通过有意识的触碰产生的压力分布，例如掐腰时手掌在腰部产生的压力分布；坐下时背部和椅背接触产生的压力分布和臀部与椅垫接触产生的压力分布。图 3.14展示了通过接触产生的压力分布。此类压力数据的分布在边缘处一般产生突变，只在受压迫区域产生压力分布，在邻近的未受压迫区域不产生压力值。分析通过接触产生的压力可以确定人体部分之间或是人体与环境间的相对位置关系。




图 3.14 掐腰和坐下时通过接触产生的压力分布

1. 人体与环境接触

人体与环境接触时会在接触区域产生一块压力分布，压力分布的形状与所接触环境的形状、硬度有关。例如，本工作中使用了具有硬质靠背和软质靠背的两种椅子，受试者在执行“靠着椅背坐”时背部产生了具有较大差异的压力部分特征。图 3.15展示了在使用不同椅子时背部压力分布的区别。与软质靠背椅子接触时产生的压力分布更加贴近人体背部的突出轮廓；压力分布自上方肩胛骨突出处出现，与下方腰窝凹陷处消失且压力值的变化更加平滑。与硬质靠背椅子接触时产生的压力分布则更加贴近椅背的形状，能够观察到压力分布具有清晰的横向分界线，且压力值在分界线处会产生较为剧烈的跳变。通过学习此类压力分布，智能衣数据不仅有望被用于重建人体姿态，也有可能被用于提取环境信息，识别正在与受试者接触的环境类型。



图 3.15 背部压力分布特征与椅背形状、材料有关

2. 人体自我接触

Müller 等人^[57]对具有目的性和功能性的自我接触进行了研究，并对人体的自我接触进行了定义，认为两个人体区域产生了自我接触当且仅当“两个人体区域在空间位置上接近（产生现实意义上的接触）并且具有一定的沿体表的距离（当接触情况消失时两者具有一定距离）”。

本工作中满足此定义的接触情况有：（1）坐姿“二郎腿坐”中双腿间的接触；（2）坐姿“抱胸坐”中两只手臂在胸前交叠，手臂之间以及手臂和胸部有接触；（3）坐姿“小腿交叉坐”中小腿间的接触；（4）站姿“前弓步”和“侧弓步”时手掌接触膝盖部位；（5）站姿“扶腰”和“掐腰”时手掌接触腰部。

根据 Müller 等人的定义，产生接触的两个身体区域在空间位置上接近。自我接触产生的压力可能被用于对关节位置进行约束。例如，当识别到左手掐腰产生的压力时可以缩短左手腕关节和左胯关节之间的位置。此部分内容超过了本工作的范围，仅为未来基于的智能衣工作提出研究方向。

3.6.2 通过运动产生的压力

第二类为关节运动时身体从内侧压迫智能衣产生的压力分布。例如，手臂和腿部弯曲时，手肘和膝盖部位会产生压力分布；此外，大臂肱二头肌和大腿肱四头肌等收缩时隆起较大的肌肉区域也会形成此类压力分布。此类压力分布产生的区域相对固定，与手肘、膝盖等关节点和肢体的位置具有强相关关系；此类压力数据的边缘处变化相较于接触压力更平滑。图 3.16展示了手肘和膝盖弯曲时的智能衣压力分布情况。




图 3.16 关节运动时可以从内部压迫智能衣产生压力，压力大小与关节运动幅度有关。

存在通过运动产生的压力是智能衣压力数据与已有的环境型智能织物系统数据之间存在较大差异的原因。此类压力数据与关节的旋转程度有关，无法通过压力数据显式地得到关节的空间位置信息。因此，本工作中使用“旋转”作为人体姿态重建的核心目标，建立体表压力数据与关节旋转之间的映射关系，再通过前向动力学算法计算人体骨架的关节坐标。

通过对数据集的简单分析，运动较频繁、范围较大的关节以及该关节联动的智能衣区域被总结于表3.3中。以上特定区域的压力大小还与关节运动幅度有关。以站姿“原地行走”为例，大腿区域的压力分布大小与抬腿幅度有关，在膝盖达到最高位置时大腿区域压力数值最大；未抬腿时大腿区域未观察到明显压力分布。这一特征也可能被用于对特定关节的旋转幅度进行约束以提高人体姿态重建的精度，此部分内容超过了本工作的范围，仅为未来基于的智能衣工作提出研究方向。

表 3.3 由于关节运动产生压力的智能衣区域与压力产生原因

关节点	智能衣区域	产生原因
手肘	智能衣上衣手肘区域	手肘关节点挤压
	智能衣上衣大臂区域	肱二头肌收缩挤压
肩膀	智能衣上衣肩胛区域	肩膀拉扯
膝盖	智能衣裤子膝盖区域	膝盖挤压
	智能衣裤子大腿区域	肱四头肌收缩挤压
胯部	智能衣上衣下摆区域	下摆随大腿运动被挤压

3.7 本章小结

本章介绍了本工作中构建体表压力分布与 3D 人体姿态数据集的过程。本工作中使用了压阻型智能衣采集 10 种站姿和 10 种坐姿下受试者的体表压力分布；使用三个单目相机采集 RGB 图片，并应用了基于视觉的 2D 人体姿态重建方法 OpenPose 和相机三角化方法生成 3D 人体姿态标签，通过提取旋转角生成了含稳定骨架长度的 3D 人体姿态标签。本工作中构建的数据集信息如表 3.4 所示。

表 3.4 数据集总览

数据集属性	数值和描述
数据集大小	约 150K 数据帧
受试者数目	7 (5 男性, 2 女性)
实验轮次	每名受试者 3 次
姿势数目	20 (10 种站姿, 10 种坐姿)
受试者年龄范围	22 - 25 岁
受试者身高范围	162 - 188 厘米
受试者体重范围	48 - 81 千克

由于 2D 矩阵形式的智能衣数据不够直观，为方便直接观察压力分布在受试者身体的位置，本工作中实现了基于 VTK 的可视化算法，将 2D 压力矩阵映射到基于体积的 3D 人体模型上。

本章对智能衣测量的体表压力分布这一新型数据进行了初探，对压力分布产生的机理和压力分布的特征进行了定性的分析，为未来有关于体表压力分布识别、分类、定位等工作确定研究方向、打下一定的基础。通过探索压力分布特征和人体活动之间的关联。

第4章 基于关节旋转预测的姿态重建算法

基于压阻型智能织物领域的研究现状，现缺少基于智能衣的姿态重建算法。因此本工作中将设计基于关节旋转预测的姿态重建算法。本章将介绍本工作中设计并实现的通过预测关节旋转角度重建姿态的深度学习算法。此算法初步建立了体表压力分布信息和关节点坐标之间的映射关系。本工作中使用了留一法交叉验证对此方法进行验证，分析智能衣在重建人体姿态上的可行性以及目前方法的不足之处。

4.1 算法设计

目前基于压阻型智能织物的全身姿态重建工作一般预测关节点的坐标，这是由于其智能织物系统均为环境型织物系统，压力数据的产生与肢体、关节等与织物表面接触有关，数据中包含显式的关节点位置信息，如图4.1(a)所示。而智能衣数据的产生与关节点旋转有关，不包含显式的关节点位置信息，如图4.1(b)所示。3.6.2节中提到，通过运动产生的压力与关节点旋转具有直接联系；因此本工作中选择预测关节点旋转信息，再通过前向动力学方法将旋转信息转换为关节点空间坐标，完成对3D人体姿态的重建。




图4.1 智能床单与智能衣的数据差异展示。(a) 智能床单数据与姿态的关联^[58]，红圈内的压力特征与关节点坐标具有相关性；(b) 智能衣数据与姿态的关联，红框内的压力特征只表示臀部的压力分布，不含有臀部关节坐标信息。

综上所述，本工作中的姿态重建算法可以被分为两个模块：（1）神经网络模块，用于建立体表压力数据与关节点旋转信息之间的映射关系；（2）前向动力学模块，用于将关节点旋转信息转换为关节点空间坐标。

4.1.1 模块一：ResNet18 神经网络

目前使用压阻型智能织物重建人体姿态的工作中通常使用卷积神经网络端到端地对关节点 2D 或 3D 坐标进行拟合。由于本工作的主要内容为验证智能衣体表压力数据在 3D 人体姿态重建上的可行性，本工作中选择使用目前通用的神经网络模型对“压力-关节旋转”关系进行拟合。基于此思路，本工作中使用了由一个 3D 卷积模块（Conv3D 层）和一个 ResNet18 模型构成的神经网络模块学习压力图像中的关节点相对旋转信息。网络结构如图 4.2 所示。

神经网络的输入为压力图像序列，本工作中以某一帧压力图像为起点，按时间顺序向前与向后分别选取等量的邻近压力图像帧构成压力图像序列，预测的目标为压力图像序列中央数据帧对应的姿态。Conv3D 层被用于提取压力图像序列中的时序特征，ResNet18 模块被用于对压力图像序列的特征进行编码。本工作中选择了 6D 旋转表示（6D Rotation Representation, r6d）来表达相对旋转信息，因为 r6d 向量比其他旋转表达方法（例如欧拉角、四元数等）拥有更好的连续性，有利于神经网络的学习。在得到 ResNet18 模型输出的 6×1 形状的 r6d 向量后，本工作中使用 Gram-Schmidt 正交化将 r6d 向量转换为 3×3 旋转矩阵。正交化过程如算法 4.1 所示。




图 4.2 使用神经网络从压力图像学习相对旋转

算法 4.1 Gram-Schmidt 正交化方法

输入：表示相对旋转的 r6d 向量 v

输出：旋转矩阵 R

- 1 $column_0 \leftarrow v[0 : 3];$
- 2 归一化 $column_0;$
- 3 $column_1 \leftarrow v[3 : 6] - (column_0 \cdot v[3 : 6])column_0;$
- 4 归一化 $column_1;$
- 5 $column_2 \leftarrow column_0 \times column_1$
- 6 $R \leftarrow (column_0 \ column_1 \ column_2);$
- 7 return R

4.1.2 模块二：前向动力学系统

在使用模块一得到关节旋转后，下一步是使用关节旋转计算关节点坐标。本工作中使用的前向动力学算法为迭代式算法，从人体骨架的根关节点（mid_hip）开始依次计算关节点坐标直到肢体末梢的关节点（nose, wrists, ankles）。

关节点的旋转可被分为全局旋转（global rotation）与相对旋转（local rotation）两种。关节点 k 的旋转被定义为由 k 的父节点 $pa(k)$ 指向 k 的向量（后文中称“肢体向量”）的旋转；其中全局旋转为使肢体向量从姿态模板中方向旋转到 3D 人体姿态标签中方向的旋转。然而，在现实的人体运动中，某一关节点的运动会影响其子关节点的位置。例如，膝盖关节点旋转时会带动脚踝关节点从而改变“膝盖-脚踝”肢体向量的朝向。相对旋转即为考虑了联动情况后，子关节点独立于父关节点的旋转分量。本工作中使用智能衣体表压力分布数据预测的旋转信息为相对旋转信息，因为相对旋转更符合现实中的人体运动规律。

设通过算法 4.1 获得的关节点旋转矩阵为 $\{\hat{\mathbf{R}}_k\}(k = 1, 2, \dots, 15)$ 。则关节点 k 的空间坐标可通过如下两个公式计算：

$$\begin{cases} \mathbf{R}_k = \mathbf{R}_{pa(k)} \cdot \hat{\mathbf{R}}_k \\ q_k = \mathbf{R}_k \cdot (p_k - p_{pa(k)}) + q_{pa(k)} \end{cases} \quad (4.1)$$

其中 $\mathbf{R}_k$, $\mathbf{R}_{pa(k)}$ 为关节点 k 和 $pa(k)$ 的全局旋转； q_k , $q_{pa(k)}$ 为关节点 k 和 $pa(k)$ 在 3D 人体姿态上的坐标， p_k , $p_{pa(k)}$ 为关节点 k 和 $pa(k)$ 在姿态模板上的坐标。公式首先使用关节点 $pa(k)$ 的全局旋转和关节点 k 的相对旋转计算关节点 k 的全局旋转 $\mathbf{R}_k$ ，再使用 $\mathbf{R}_k$ 旋转对应肢体向量，从而得到关节点 k 的空间坐标。由于此公式被迭代计算，在计算关节点 k 的全局旋转 $\mathbf{R}_k$ 时，其父节点的全局旋转 $\mathbf{R}_{pa(k)}$ 已被确定。根关节点 mid_hip 不存在父关节点的全局旋转，因此其相对旋转即为全局旋转。图 4.3 展示了使用前向动力学重建姿态的迭代过程。




图 4.3 使用前向动力学重建人体姿态的流程图。（a）左腿膝盖未转动时，左腿处于姿态模板状态；（b）左腿膝盖转动，左腿脚踝未转动；此时膝盖转动改变了脚踝的位置；（c）左腿脚踝转动，此时完成了对左腿动作的重建。

4.1.3 损失函数设计

目前的基于压阻型智能织物重建人体姿态的工作在训练神经网络时通常使用关节点平均位置误差和肢体长度误差两项作为损失函数。由于已有的工作通常直接预测关节点坐标，需要使用肢体长度误差来约束人体骨架，减少不合理姿态的产生。本工作中使用的人体姿态标签具有稳定、已知的人体骨架，故不需要使用肢体长度作为损失函数。

本工作中使用了关节点平均位置误差 $\mathcal{L}_2$ 作为损失函数，用于直接约束重建结果的关节点坐标。设 N 为关节点数量， q_i 和 $\hat{q}_i$ ($i \in \{1, 2, \dots, N\}$) 分别为标签关节点位置和重建结果中的关节点位置，则 $\mathcal{L}_2$ 被计算如下：

$$\mathcal{L}_2 = \frac{1}{N} \sum_{i=1}^N \|q_i - \hat{q}_i\| \quad (4.2)$$

本工作中对姿态重建方法的使用是“端到端”的，即对模块一的中间输出没有进行监督操作还是在模块二完成对关节点坐标的计算后再计算损失函数值并对模块一的网络参数进行优化。因此，本工作中不需要控制模块一的输出结果是否为关节点的相对旋转，只需要使用从相对旋转计算关节点坐标的代码即可保证神经网络的输出结果为代表了关节点相对旋转的 r6d 向量。

4.2 实验评估

本节将介绍用于评估深度学习方法的姿态重建实验。针对受试者的留一法交叉验证 (Leave-One-Out, LOO) 被用于评估深度学习方法在姿态重建任务上的性能。本节也将介绍姿态重建误差较大的情况以及压阻型智能衣被用于长时间连续进行人体姿态重建的可能。本工作中使用了 RTX4090 显卡作为训练模型参数的硬件设备。本工作中使用的数据集帧数约 150K，模型训练时对于每一帧选取改帧前后长度为 5 的序列组成时间窗口作为样本。进行 LOO 交叉验证时约 110K 样本被用于训练，40K 样本被用于测试。Batch 大小被设置为 32，学习率为 5×10^{-4} ，使用的优化器为 Adam 优化器，模型被固定训练 20 个 epoch。

4.2.1 评价指标

目前被最广泛使用的姿态重建评价指标为平均每关节点位置误差 (Mean Per Joint Position Error, MPJPE)，其直观地以关节点真实位置和预测位置之间的欧式距离来评价预测结果。设 N 为关节点数量， q_i 和 $\hat{q}_i$ ($i \in \{1, 2, \dots, N\}$) 分别为关节点真实位置和预测位置的坐标，则 MPJPE 的计算方法如下：

$$\text{MPJPE} = \frac{1}{N} \sum_{i=1}^N \|q_i - \hat{q}_i\| \quad (4.3)$$

部分工作中也会使用正确关节点百分比 (Percentage of Correct Keypoints) 来表示姿态重建的结果。当某一关节点的预测误差低于设置的阈值时认为此关节点的预测是准确的。阈值通常被设置为躯干对角线长度 (例如左肩膀到右胯部的距离) 的 50% 或 20%，此时指标被记作 PCK@0.5 与 PCK@0.2。此外，在一些使用人体动力学重建人体姿态 (例如，使用可穿戴 IMU 系统的) 或是关注重建单个关节点运动 (例如，使用集成了电容传感器的袖套) 的工作中也会使用关节点相对旋转角度误差来评价姿态重建的结果。

本工作中使用关节点位置误差 MPJPE (mm) 对实验结果进行评估。由于 3D 人体姿态标签被转移进智能衣穿戴者的局部坐标系中，本工作中的 MPJPE 误差是在智能衣穿戴者的局部坐标系下计算的，不包含全局位置信息 (穿戴者在外界环境中的具体位置)。

4.2.2 Leave-One-Out 交叉验证

本工作中针对受试者进行了留一法交叉验证 (Leave-One-Out, LOO)，本实验用于检验神经网络模型在处理未知受试者时的泛化性以及评估不同受试者之间的数据分布是否具有相似性。7 名受试者被随机分为 4 组 (3 组 2 人，1 组 1 人)。每次实验时选取其中 3 组进行训练，1 组进行验证。随机划分获得的分组如表 4.1 所示 (受试者编号按照姓名拼音首字母顺序)，四次实验在验证集上得到的平均关节点位置误差为 98.71mm。本工作将从不同受试者、不同关节点和不同姿态三个方面分别分析实验结果。

表 4.1 Leave-One-Out 实验分组划分

折号	受试者编号
第 1 折	受试者 2, 受试者 7
第 2 折	受试者 5, 受试者 3
第 3 折	受试者 4
第 4 折	受试者 1, 受试者 6

人体姿态重建的精度和受试者的体型有关，表 4.2 展示了每名受试者的体型信息和对应的姿态重建误差。7 名受试者中受试者 2 号为离群样本，他的身高为 188cm，高出其他受试者 26%。因此受试者 2 号的体表压力分布特征与其他受试者有较大不同，姿态重建误差也达到了 120.91mm。由受试者体型带来的重建误差还体现在对于特定肢体动作的错误判断中，本工作将在失败案例中进一步分析此类情况。受试者 4 号的姿态重建精度最高，可能的原因为交叉验证的分组并非平均划分，验证受试者 4 号数据时用于训练神经网络的训练集样本量更大。

不同关节点的重建精度存在差异。图 4.4 展示了每个关节点的重建误差，距离躯干越远的关节点的精度越低。这一现象可能由两个原因导致：(1) 使用前向动力学算法重建姿态时存在误差累积的现象；在子节点旋转被正确预测的情

表 4.2 不同受试者的姿态重建误差

编号	身高	体重	性别	折号	重建误差
1	162cm	48kg	女	4	97.63mm
2	188cm	75kg	男	1	120.91mm
3	173cm	60kg	男	2	106.23mm
4	163cm	51kg	女	3	86.19mm
5	170cm	58kg	男	2	95.04mm
6	178cm	75kg	男	4	92.14mm
7	183cm	81kg	男	1	96.39mm

况下,对父节点的错误预测会导致子节点位置错误。(2)距离躯干越远的关节点拥有约束更小、范围更大的空间分布;这样的空间分布给网络预测带来困难。




图 4.4 不同关节点的平均关节点位置误差。

为了统计累积误差带来的影响,本工作中将父节点位置对齐后重新计算关节点的位置误差,此时的位置误差即为独立预测某一关节点位置时的误差。对齐父节点后的关节点位置误差为 71.54mm,也即 27.17mm 的关节点位置误差来源于前向动力学方法导致的误差累积。各个关节点的累积误差如表 4.3 所示。

表 4.3 前向动力学给不同关节点带来的累积误差

关节点名称	关节点位置误差 (mm)	对齐父节点后位置误差 (mm)	累积误差 (mm)
neck	83.58	83.58	0
nose	137.53	89.82	47.71
l-shoulder	91.69	37.88	53.81
r-shoulder	90.28	37.52	52.76
l-elbow	110.97	85.63	25.34
r-elbow	117.81	91.74	26.07
l-wrist	154.51	109.34	45.17
r-wrist	163.80	111.85	51.95
l-hip	27.30	27.30	0
r-hip	26.95	26.95	0
l-knee	96.27	92.53	3.74
r-knee	99.50	95.62	3.88
l-ankle	138.11	90.29	47.82
r-ankle	142.28	93.08	49.02

对于父节点的不准确预测也会在模型训练上影响对子节点分布的学习。在未来工作中可选的方向为：使用概率分布代替关节点精确坐标进行关节点空间位置的表示；通过模糊父关节点的位置可能消除累积误差的影响。

本工作中统计了 20 种不同姿态下的平均关节点位置误差如图 4.5 所示。具体的姿态类别、名称和关节点误差如表 4.4 所示。其中误差较高的（110mm 以上）的姿态有“侧弓步”、“弯腰摸脚趾”和“侧坐（左、右）”四种。本工作中将在 4.3 中详细分析。




图 4.5 不同姿态的平均关节点位置误差。

表 4.4 不同姿态下的平均关节点位置误差 (mm)

姿态类别	姿态名称	姿态编号	姿态重建误差 (mm)
站姿	转体	1	92.54
	侧向伸展	2	106.30
	前弓步	3	96.56
	侧弓步	4	117.23
	单手与双手扶腰	5	74.27
	弯腰摸脚趾	6	152.30
	深蹲起	7	91.23
	原地行走	8	85.90
	手臂平举	9	103.75
	单手与双手掐腰	10	67.03
坐姿	正坐，手放在膝盖上	11	85.18
	二郎腿坐，左腿在上	12	98.46
	二郎腿坐，右腿在上	13	97.73
	侧坐，左侧朝向椅背	14	117.05
	侧坐，右侧朝向椅背	15	117.59
	正坐，腰部垫枕头	16	91.44
	双手抱胸坐	17	88.81
	抱腿坐	18	109.37
	正坐，手放在扶手上	19	89.03
	小腿交叉坐	20	102.01

4.3 重建案例分析

Leave-One-Out (LOO) 交叉验证验证了智能衣所采集的体表压力数据具有被用于 3D 人体姿态重建的可能。本节中将通过具体案例分析本工作中使用的基于关节旋转预测的方法在 3D 人体姿态重建任务上的表现, 根据重建结果的不足提出可能的改进方法。图 4.6 展示了两种姿态对应的标签、重建结果和压力数据。




图 4.6 坐姿“抱胸坐”和站姿“原地行走”的案例展示。包括 3D 姿态标签、姿态重建结果和对应帧的体表压力数据。

图 4.6 中的案例展示了本工作中提出的基于关节旋转预测的人体姿态重建方法在 3D 人体姿态重建任务上取得了以下两个方面的成果：（1）可以重建出对应姿态种类的肢体动作，通过观察可以分辨重建结果属于哪种姿态；（2）可以重建出执行姿态过程中的中间动作，通过展示按时间排序的帧能够观察到受试者从站立姿态到最终完成动作的过程。

在本工作中使用的 20 种姿态中，“弯腰摸脚趾”、“侧弓步”和“侧坐（左、右）”的重建精度较低。本节中将通过具体案例分析其原因并提出改进措施。




图 4.7 “弯腰摸脚趾”姿态的误差分析。(a) 平均关节点位置误差；(b) 重建结果案例；(c) 重建难度与智能衣穿戴者体型的关系。

如图 4.7 (a) 所示,“弯腰摸脚趾”动作的误差主要集中在上半身的关节点。具体地,误差来源于对弯腰动作的预测不精确,如图 4.7 (b) 所示,重建结果对于具体弯腰幅度的预测不正确,导致了上半身关节点的重建精度较低。“弯腰”幅度的预测难度可能来源于智能衣穿戴者的体型,不同体型的受试者在执行同一幅度“弯腰”动作时可能产生区别较大的压力分布。如图 4.7 (c) 所示,较胖的穿戴者(左)在弯腰较浅时产生了更大面积、数值更高的压力分布,而较瘦的穿戴者(右)在弯腰较深时产生的压力分布在面积与数值上均弱于较胖的穿戴者。因此,本工作中使用的方法无法在未知受试者体型的基础上成功预测穿戴者的弯腰幅度。针对此类失败案例,可能的改进措施有:使用高压时段数据和当前的预测结果对穿戴者体型进行预测。




图 4.8 “侧弓步”姿态的误差分析。

如图 4.8 (a) 所示,“侧弓步”动作的重建误差的分布与整体有相似的规律,上半身和下半身的关节点位置误差基本一致,区别在于“侧弓步”动作对于腿部关节点的重建精度更低,如图 4.8 (b) 中红色圆圈标注位置所示,重建“侧弓步”腿部动作时具有明显的位置误差。可以从图 4.8 (b) 观察到,重建结果中 3D 人体姿态的下蹲幅度要深于姿态标签,因此类似“弯腰摸脚趾”中穿戴者体型影响数据分布的情况亦可能存在。




图 4.9 “侧坐（左、右）”姿态的误差分析。

如图 4.9 (a) 所示,“侧坐 (左、右)”动作的重建误差的分布与整体有相似的规律,上半身和下半身的关节点位置误差基本一致,且具有“距离躯干越远的关节点精度越低”的规律。在具体案例中发现重建结果中对于上半身的整体侧摆动作存在遗漏。图 4.9 (b) 中姿态标签更倾斜向右侧而重建结果更偏向于身体竖直。这种失败案例可能与智能衣的设计有关,由于智能衣为上下分体设计,当身体以腰部为轴转动时,智能衣可能无法捕捉到对应的压力变化,此现象将在后文中详细分析。

4.4 特殊失败案例

在第4.3节中，本工作从受试者、关节点和姿态三个方面分析了 Leave-One-Out (LOO) 交叉验证实验的结果，并针对重建精度较低的四种姿态进行了详细分析，提供了相应的案例。在上述案例以外，本工作中发现了与算法设计关联较弱，由智能衣硬件设计或体表压力数据特性导致的失败案例，本节中将针对上述两类案例进行分析。两类失败案例被简要描述如下：

- (1) **智能衣设计导致的失败案例。**目前智能衣设计为“上衣”结合“裤子”的分体式设计，上衣和裤子之间不存在相互连接的部分。因此，当受试者上半身整体运动时，智能衣无法捕捉到具有相应特征的体表压力分布，例如上半身整体的侧摆（如“侧坐”案例中展示）和转体（本节中将展示）。
- (2) **数据模糊性导致的失败案例。**本工作中发现在受试者执行不同姿态的过程中，智能衣可能测量到类似的体表压力分布特征，本工作中将这种现象称为“数据模糊”。在使用单帧数据或是较短时间窗口进行姿态重建时，数据模糊现象可能导致连续数帧的高误差预测。

4.4.1 智能衣设计导致的失败案例

智能衣存在无法捕获到压力分布的情况。本节中将通过姿态“转体”中的重建案例分析与智能衣设计有关的这一类失败案例。如图4.10所示，姿态标签和重建结果的主要区别为上半身的转体方向，执行此部分运动的人体区域为腰部，但是在体表压力数据的腰部区域并没有观察到与“转体”动作有关的特征压力。此案例说明，智能衣穿戴者的“转体”动作在一些情况下无法被智能衣捕捉，从而给姿态重建任务带来困难。




图4.10 智能衣设计导致的失败案例。红色方框标出的为腰部区域的压力数据，其中数据点由智能衣穿戴者佩戴的电路板导致，与转体动作无关。

由于此类失败案例由智能衣设计导致，在算法和数据方向难以提供针对性的处理。一种解决方法是在智能衣上衣和裤子之间增加连接用的传感阵列，但是此方法会导致智能衣穿戴上的麻烦，与智能衣本身舒适、易穿戴的特性和设计理念不符；另一种解法是引入其他模态，比如在腰部区域使用单个 IMU 检测腰部旋转的角速度，从而对智能衣无法捕捉的“转体”行为进行重建。

4.4.2 数据模糊性导致的失败案例

压阻型智能织物系统的数据来源于人体与织物表面的接触。当人体与织物表面的接触不明显时,织物系统无法采集到足够推理出人体活动的数据,即“数据模糊”。Clever 等人在使用压阻型智能床单数据重建人体姿态时指出:当受试者腿部与床单缺少接触时,使用智能床单数据重建该腿部姿态时具有更高的不确定性;当受试者足部与床单接触时,腿部各个关节点的重建精度均得到提升。

与智能床单等环境型织物传感系统类似,智能衣系统在数据量不足时也会受到“数据模糊”的影响。3.6节中说明了,智能衣采集到的压力分布区域大小与数值大小随着人体运动的幅度的增大而增大。当受试者处于正常直立动作时,智能衣表面不存在明显压力分布;当受试者刚刚开始运动时,智能衣表面的压力分布会经过一个“分布面积较小、压力数值较小”的起步阶段。此阶段下的智能衣数据可能无法体现明显的压力分布特征,但是人体姿态已经具有显著区别。不同动作下姿态差异和压力差异的原始数据如表 4.5 所示。图 4.11 展示了在执行站姿“蹲起”和站姿“前弓步”时智能衣压力分布随着动作幅度的变化情况。起步阶段下的智能衣压力分布区分不明显(压力分布均产生在腰部、大腿和臀部),但人体姿态具有较大区别(“蹲起”动作的两腿距离较近而“前弓步”动作两腿距离较远)。本工作中使用 3D 姿态坐标之间的距离和压力矩阵之差的二范数作为量化姿态差异和压力差异的指标。本工作中使用站姿“前弓步”和站姿“蹲起”动作序列中按序的 5 帧展示数据模糊的产生原理,其中第 1 帧均为正常直立动作,第 5 帧均为动作幅度达到最大。

表 4.5 不同动作下的姿态差异与压力差异数据

帧号	第 1 帧	第 2 帧	第 3 帧	第 4 帧	第 5 帧
姿态差异 (mm)	109.20	108.20	224.68	256.63	310.93
压力差异	1449.98	1444.76	1671.36	3815.10	5059.68

本工作中在分析数据模糊案例时出现了连续多帧严重预测失败的情况,如图 4.12 所示。在对大量实验样例进行分析时难以界定某样例的重建错误是否是由数据模糊导致的。在本案例中,数据模糊现象使得“前弓步”姿态被错误重建为了“蹲起”姿态,但分类器可能并不适用于界定数据模糊,因为当压力特征不明显时分类器的分类精度同样会下降。针对本案例可以尝试使用插值拟合方法修改膝盖、脚踝等关节点的运动轨迹。未来工作中可以尝试使用 GRU、LSTM 等时序神经网络结构解决单帧或较短窗口内压力特征不明显的问题,或加入追踪关节点加速度的损失函数项。




图 4.11 数据模糊的产生原理：随着动作幅度的变化，姿态差异和压力差异的变化幅度存在不一致性。红色部分即为数据模糊更容易产生的阶段。(a) 站姿“前弓步”标签与压力图像；(b) 站姿“蹲起”标签与压力图像；(c) 姿态标签差异与压力差异随时间变化情况。本工作中使用 3D 姿态坐标之间的距离和压力矩阵之差的二范数作为量化姿态差异和压力差异的指标。




图 4.12 连续多帧出现数据模糊情况。(a) 姿态重建结果，红色圆圈位置为严重重建失败的关节；(b) 姿态标签。

4.5 误差时间分布分析

基于 IMU 的姿态重建方法在长时间使用时误差会逐渐累积, 出现重建误差随时间增大的“漂移”现象。此现象给基于 IMU 的方法带来算法上的要求, 也为其在日常生活中的使用带来限制。

为了验证压阻型智能衣用于长时间人体姿态重建的可能性, 本工作中对姿态重建误差随时间的变化情况进行分析。数据采集实验为连续进行, 通常持续 20-30 分钟; 一次实验因此可以被看作对智能衣时长 20-30 分钟的连续使用。




图 4.13 同一名受试者三次实验中预测误差随时间变化

图 4.13展示了受试者 5 三次实验中姿态重建误差随时间的变化关系, 从中可以观察到两点: (1) 同一次实验中, 智能衣重建人体姿态的误差分布并没有出现随着时间上升的“漂移”现象; (2) 不同次实验中, 姿态重建算法对相同姿态的重建误差基本一致。此统计结果展示了在连续使用智能衣时智能衣的数据具有稳定性, 不会使得姿态重建算法产生累计误差而“漂移”; 也展示了智能衣在多次使用时其数据具有一致性。

从图 4.13中可以观察到预测误差随时间有抖动现象。这是由于本工作中使用的输入数据为长度为 5 的时间窗口, 根据相机 15Hz 的帧率设置, 此窗口在现实中包含约 0.3 秒的数据, 而本工作使用的数据集中包含的人类活动主要为慢速活动, 因此约 0.3 秒的时间窗口能够提供的上下文信息有限。未来工作中需要使用 GRU、LSTM 等时序神经网络结构和关节点加速度约束等改善模型的平滑性。

4.6 关于智能衣覆盖面积的消融实验

本工作中使用的压阻型智能织物系统为全身覆盖型的智能衣,为了研究增大织物覆盖面积是否有助于提升姿态重建的精度,本工作中进行了关于智能衣覆盖面积的消融实验。通过对原 $2 \times 64 \times 32$ 压力图像进行剪裁,仅保留上衣部分 $2 \times 26 \times 32$ 和裤子部分 $2 \times 38 \times 32$ 。重新进行了 Leave-One-Out 交叉验证实验。表 4.6 展示了在只使用上衣数据或裤子数据时各个关节点重建误差的变化情况,表中的误差对比是与使用全部数据时重建结果的比较结果。

表 4.6 只使用上衣或裤子数据和使用全部数据时的平均关节点位置误差 (mm) 对比

	使用上衣 (误差对比)	使用裤子 (误差对比)	使用全部数据
neck	98.14 (14.56↑)	112.55 (28.97↑)	83.58
nose	154.75 (17.22↑)	182.75 (45.22↑)	137.53
l-shoulder	106.07 (14.38↑)	121.63 (29.94↑)	91.69
r-shoulder	104.19 (13.91↑)	118.65 (28.37↑)	90.28
l-elbow	120.98 (10.01↑)	167.69 (56.72↑)	110.97
r-elbow	125.80 (7.99↑)	172.01 (54.2↑)	117.81
l-wrist	166.05 (11.43↑)	243.93 (89.42↑)	154.51
r-wrist	174.69 (10.89↑)	246.49 (82.69↑)	163.80
l-hip	27.35 (0.05↑)	26.93 (0.37↓)	27.30
r-hip	27.07 (0.12↑)	26.77 (0.18↓)	26.95
l-knee	123.39 (27.12↑)	111.24 (14.97↑)	96.27
r-knee	125.74 (26.24↑)	118.15 (18.65↑)	99.50
l-ankle	179.47 (41.36↑)	158.78 (20.67↑)	138.11
r-ankle	177.98 (35.70↑)	165.32 (23.04↑)	142.28
average	114.11 (15.40↑)	131.53 (32.82↑)	98.71

从表 4.6 中可以得到两个结论: (1) 只使用上衣数据或只使用裤子数据时, 3D 人体姿态的重建精度均有所下降; 且使用裤子数据时平均关节点位置误差的增加更明显; (2) 使用上衣数据时对上半身关节点的重建精度优于只使用裤子数据; 使用裤子数据时对下半身关节点的重建精度优于只使用上衣数据。




图 4.14 只使用上衣或裤子数据和使用全部数据在重建不同姿态时的结果对比

从图 4.14 中可以得到两个结论：（1）对于大部分站姿动作，只使用上衣数据时的重建结果精度较高，例如站姿 2 “侧向伸展”；也存在部分只使用上衣数据或裤子数据时重建精度接近的动作，例如站姿 8 “原地行走”；（2）对于大部分坐姿动作，只使用上衣数据或裤子数据时的重建结果接近；对于涉及特殊下肢动作的坐姿如坐姿 12、13 “二郎腿坐，左、右腿在上”时，只使用裤子数据时的重建精度会更高；对于涉及上肢动作的坐姿如坐姿 17 “双手抱胸坐”时，只使用上衣数据时的重建精度会更高。本工作中将通过分析具体案例解释上述结论。




图 4.15 站姿 2 “侧向伸展”在只使用上衣数据和裤子数据时，重建结果和姿态标签的对比结果。红色区域标注了与姿态相关的压力分布。

图 4.15 展示了站姿 2 “侧向伸展”在只使用上衣数据和裤子数据时，重建结果和姿态标签的对比结果。由于站姿 2 “侧向伸展”中的抬手动作只影响身体局部的压力分布，在裤子区域不产生对应的压力分布，只使用裤子数据时姿态重建算法无法预测抬手动作。在上衣区域，抬手动作在手臂对应侧的躯干上产生压力分布，此部分压力分布可以被姿态重建算法学习并成功预测抬手动作。




图 4.16 站姿 8 “原地行走”在只使用上衣数据和裤子数据时，重建结果和姿态标签的对比结果。红色区域标注了与姿态相关的压力分布。

图 4.16展示了站姿 8 “原地行走”在只使用上衣数据和裤子数据时,重建结果和姿态标签的对比结果。和站姿 2 “侧向伸展”只在上衣区域产生压力分布不同,站姿 8 “原地行走”在上衣和裤子区域都产生了压力分布。上衣区域的压力分布在抬起的腿的躯干对侧,裤子区域的压力分布在抬起的腿的大腿、小腿、膝盖部位。因此,只使用上衣数据或只使用裤子数据都可以重建出行走动作。




图 4.17 坐姿 11 “正坐,手放在膝盖上”在只使用上衣数据和裤子数据时,重建结果和姿态标签的对比结果。红色区域标注了与姿态相关的压力分布。

图 4.17展示了坐姿 11 “正坐,手放在膝盖上”在只使用上衣数据和裤子数据时,重建结果和姿态标签的对比结果。此坐姿在上衣和裤子区域都产生了压力分布。上衣区域的压力分布在腹部和接触椅子的背部,腹部压力为坐下时智能衣褶皱导致;裤子区域的压力分布在臀部和腿部部位。因此,只使用上衣数据或只使用裤子数据都可以重建出正坐动作。

图 4.18展示了坐姿 13 “二郎腿坐,右腿在上”和坐姿 17 “双手抱胸坐”在只使用上衣数据和裤子数据时,重建结果和姿态标签的对比结果。和本工作中设置的基础坐姿“正坐”不同,“二郎腿坐”和“双手抱胸坐”在腿部和手部增加了局部肢体动作。在图 4.18中“压力数据”列可以看到,“二郎腿坐”姿势只在裤子区域产生了和腿部运动相关的压力分布,因此只使用上衣数据进行姿态重建时算法只预测到了基础的“正坐”姿态,而只使用裤子数据重建时则可以还原“二郎腿坐”的抬腿动作;同理,“双手抱胸坐”姿势只在衣服区域产生了和手部运动相关的压力分布,因此只使用上衣数据进行姿态重建时算法可以还原“抱胸”动作,而只使用裤子数据重建时则只预测到了基础的“正坐”姿态。

通过上述消融实验,本工作中指出了部分肢体动作只在局部区域产生压力分布的特征,并展示了在缺少压力传感区域的情况下,部分肢体动作无法被正常重建的失败案例。本工作中展示的姿态重建案例说明了使用覆盖区域更大的织物传感设备有助于提高 3D 姿态重建的精度和算法鲁棒性。




图 4.18 坐姿 13 “二郎腿坐，右腿在上”和坐姿 17 “双手抱胸坐”在只使用上衣数据和裤子数据时，重建结果和姿态标签的对比结果。红色区域标注了与姿态相关的压力分布。

4.7 本章小结

本章介绍了使用智能衣压力数据重建 3D 人体姿态的深度学习方法。本工作中首先使用 3D 卷积层提取输入窗口中压力数据序列的时序特征，再将特征输入 ResNet18 网络进行学习，输出各关节点相对父关节点的相对旋转矩阵的 6D 表示（r6d 向量）。使用 Gram-Schmidt 正交化方法将 r6d 向量转换为旋转矩阵后，本工作使用了基于 HybrIK^[27] 的前向动力学模型计算关节点的 3D 坐标，使用了平均关节点位置误差作为损失函数训练网络模型。

本工作中的姿态重建算法在 Leave-One-Out（LOO）交叉验证中达到了 98.71mm 的关节点位置误差。LOO 交叉验证实验体现了本工作中设计的姿态重建算法在面对未知受试者数据时的泛化性。本工作中从不同受试者、不同关节点和不同姿态角度对重建结果进行了分析。结果表明受试者的体型对姿态重建精度存在影响，不同体型受试者在执行同一动作时的体表压力分布模式具有差异；不同关节点的重建精度存在差异，离躯干较远的关节点重建精度低，原因之一为使用前向动力学算法时存在的误差累积；不同姿态的重建精度存在差异，其中具有代表性的失败案例可被归类为“智能衣设计导致的失败”和“数据模糊性导致的失败”两类。“智能衣设计导致的失败”的产生原因为智能衣分体设计导致其对腰部转动的不敏感；“数据模糊性导致的失败”的产生原因为：在动作幅度较小的阶段，存在姿态变化较明显而压力数据变化不明显的阶段，此阶段中易混淆不同动作下的体表压力分布。本工作中展开了针对智能衣覆盖面积的消融实验，只使用上衣或裤子数据重建全身姿态。实验结果说明，存在一些只对

局部压力分布产生影响的动作，缺少此部分压力分布会导致 3D 姿态重建的不准确。因此，增加织物覆盖面积有助于提升姿态重建算法的精度和鲁棒性。

基于目前对压阻型智能衣的研究现状，本工作为第一个使用压阻型智能衣进行人体姿态重建的工作，故不存在可以进行对比的使用压阻型智能衣的工作。本工作对人体姿态重建的精度与已有的使用其他压阻型智能织物设备的工作对比如表 4.7 所示。通过姿态重建实验，本工作验证了使用智能衣采集的体表压力分布数据重建人体姿态的技术可行性。实验结果展示了使用压阻型智能衣在开放环境以及长时间使用中重建人体姿态的可能性。

表 4.7 与其他压阻型智能织物工作对比

作者，时间↓	数据来源	人体姿态类型	模型类型	姿态重建精度
Clever 等人 ^[19] ,2018	智能床单	全身姿态	CNN	MPJPE 约 76mm
Cases 等人 ^[54] ,2019	智能床单	全身姿态	CNN	MPJPE 约 80mm
Luo 等人 ^[18] ,2021	智能地毯	全身姿态	CNN	MPJPE 约 100mm
Davoodnia 等人 ^[56] ,2021	智能床单	全身姿态	OpenPose	PCK 95%
Davoodnia 等人 ^[55] ,2023	公开数据集 ^[18]	全身姿态	ViT + MAE	PCK 95%
Zhang 等人 ^[46] ,2024	智能膝套	下半身姿态	LSTM	MPJAE 约 7 度
本工作	智能衣	全身姿态	ResNet	MPJPE 约 98mm

第5章 总结与展望

5.1 工作总结

人体姿态重建在许多领域都有着广泛的应用，但是目前广泛使用的基于计算机视觉（Computer Vision, CV）和基于惯性测量单元（Inertial Measurement Unit, IMU）的方法在开放环境中重建人体姿态时存在一定的问题。压阻型智能织物作为一种新型传感器，在人类活动识别等领域有着广泛应用。压阻型智能衣可以解决目前方法在开放环境中重建人体姿态的一些问题。然而，基于已有的人体姿态重建和压阻型智能织物的工作，使用压阻型智能衣重建人体姿态仍存在以下两个问题：（1）缺少压阻型智能衣数据和对应 3D 人体姿态数据集；（2）缺少使用压阻型智能衣数据重建 3D 人体姿态的算法。

针对以上两个问题，本工作中设计智能衣数据采集实验并采集了受试者不同姿态下的智能衣压力数据，并使用深度学习方法实现了 3D 人体姿态的重建。具体包含以下工作内容：

- （1）**工作内容一：压阻型智能衣数据集构建和分析。**本工作中设计了使用压阻型智能衣和单目相机同步采集压力数据和 RGB 数据的实验方案；招募了 7 名受试者进行了共 21 人次的实验，采集了 20 种不同姿态下智能衣采集到的体表压力分布数据并用视觉方法生成了对应的 3D 人体姿态标签，制作了总计约 150K 数据帧的智能衣数据集。本工作中分析了智能衣压力数据的产生原理并对其进行定性的分析，为未来智能衣压力数据应用于环境接触和自我接触打下基础。
- （3）**工作内容二：基于压阻型智能衣的人体姿态重建算法。**本工作中设计并实现了基于深度神经网络和前向动力学模型的人体姿态重建方法。本工作中使用留一法交叉验证对此方法进行评估，最终在 Leave-One-Out (LOO) 交叉验证中达到了 98.71mm 的关节位置误差。

5.2 工作展望

本工作还存在以下不足：

- （1）本工作中构建的压阻型智能衣数据集中不包括卧床情况下的体表压力分布数据和 3D 人体姿态标签。卧床人体姿态重建是人体姿态重建领域的一个重要分支，在健康看护、睡眠监测等领域均有应用。在未来工作中需要会增加关注对卧姿的重建。
- （2）本工作中使用了基础的三角化算法（Direct Linear Transform, DLT）进行

3D 人体姿态标签生成,而标签精度也会对神经网络模型的学习与预测产生影响。在目前的研究中,存在基于角度误差优化的三角化算法能够提供更高的相机三角化精度。在未来的工作中需要尝试使用更高精度的三角化算法,并使用梯度下降^[18]等方式对 3D 人体姿态标签进行优化。

- (3) 本工作中只尝试了 ResNet18 模型作为神经网络的核心去重建 3D 人体姿态。Conv3D 层与 ResNet18 模型只能对时序输入进行基础的特征提取。第4.4.2节中指出了智能衣数据输入在时间窗口较短时存在数据模糊性的问题。在未来工作中,需要更加关注智能衣数据的时序信息提取,考虑使用 LSTM、GRU 等时序神经网络结构实现更高精度的 3D 人体姿态重建;或是使用基于注意力机制的神经网络结构,例如 Transformer,对局部压力分布进行针对性的学习。
- (4) 本工作中使用的神经网络模型只对人体姿态中关节的相对旋转信息进行了学习。在姿态重建实验中,每名受试者的专属姿态模板被作为先验信息输入到网络中;然而,受试者的肢体长度信息应当作为网络预测任务的一部分,在实际应用时神经网络模型应当达到在不知道任何有关受试者信息的条件下重建人体姿态。在未来工作中,需要加入使用压阻型智能衣数据预测受试者肢体长度的部分,将肢体长度预测任务和 3D 人体姿态重建任务合并为一个任务进行模型训练。

本工作中通过体表压力分布数据对人体姿态信息进行了推理。然而压力分布有可能被用于更加广泛的研究领域。本工作还有望被推广到以下工作内容:

- (1) **基于体表压力分布的环境接触分析。**第 3.6 节中分析了智能衣压力数据的产生机理。通过接触产生的压力可以一定程度上反应和人体接触的环境特征。通过识别此类压力区块,智能衣压力数据有望被用于环境接触分析,推理智能衣穿戴者的生活环境、工作习惯等。
- (2) **基于体表压力分布的交互系统设计。**除了“被动地”观测不同姿态下的体表压力分布,智能衣采集到的数据还可以被用于“主动地”与智能设备进行交互。例如设计特定的动作,将此动作下的压力数据作为交互指令发送给其他的智能设备。压阻型智能衣有可能在智能设备交互上产生应用价值。

参考文献

- [1] VIANELLO L, MOURET J B, DALIN E, et al. Human posture prediction during physical human-robot interaction[J]. IEEE Robotics and Automation Letters, 2021, 6(3): 6046-6053.
- [2] HUANG Z, LIU Y, FANG Y, et al. Video-based fall detection for seniors with human pose estimation[C]//2018 4th international conference on Universal Village (UV). IEEE, 2018: 1-4.
- [3] WANG J, QIU K, PENG H, et al. Ai coach: Deep human pose estimation and analysis for personalized athletic training assistance[C]//Proceedings of the 27th ACM international conference on multimedia. 2019: 374-382.
- [4] WANG J, TAN S, ZHEN X, et al. Deep 3d human pose estimation: A review[J]. Computer Vision and Image Understanding, 2021, 210: 103225.
- [5] CAO Z, SIMON T, WEI S E, et al. Realtime multi-person 2d pose estimation using part affinity fields[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017.
- [6] LEE C J, LEE J K. Inertial motion capture-based wearable systems for estimation of joint kinetics: A systematic review[J]. Sensors, 2022, 22(7): 2507.
- [7] TEUFL W, MIEZAL M, TAETZ B, et al. Validity of inertial sensor based 3d joint kinematics of static and dynamic sport and physiotherapy specific movements[J]. PloS one, 2019, 14(2): e0213064.
- [8] ZHOU B, SUH S, REY V F, et al. Quali-mat: Evaluating the quality of execution in body-weight exercises with a pressure sensitive sports mat[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2022, 6(2): 1-45.
- [9] ZHOU B, CHENG J, SUNDHOLM M, et al. From smart clothing to smart table cloth: Design and implementation of a large scale, textile pressure matrix sensor[C]//Architecture of Computing Systems—ARCS 2014: 27th International Conference, Lübeck, Germany, February 25-28, 2014. Proceedings 27. Springer, 2014: 159-170.
- [10] 郭涛. 压阻阵列型智能织物通用特征集计算和选择方法[D]. 中国科学技术大学, 2022.
- [11] CHENG J, SUNDHOLM M, ZHOU B, et al. Smart-surface: Large scale textile pressure sensors arrays for activity recognition[J]. Pervasive and Mobile Computing, 2016: 97-112.
- [12] ZHOU B, CHENG J, SUNDHOLM M, et al. From smart clothing to smart table cloth: Design and implementation of a large scale, textile pressure matrix sensor[C]//Architecture of Computing Systems – ARCS 2014. Cham: Springer International Publishing, 2014: 159-170.
- [13] ZHOU B, CHENG J, SUNDHOLM M, et al. Smart table surface: A novel approach to pervasive dining monitoring[C]//2015 IEEE International Conference on Pervasive Computing and

- Communications (PerCom). IEEE, 2015: 155-162.
- [14] LIU J J, HUANG M C, XU W, et al. Bodypart localization for pressure ulcer prevention[C]// 2014 36th annual international conference of the IEEE engineering in medicine and biology society. IEEE, 2014: 766-769.
- [15] ZHOU B, SUNDHOLM M, CHENG J, et al. Measuring muscle activities during gym exercises with textile pressure mapping sensors[J]. *Pervasive and Mobile Computing*, 2017, 38: 331-345.
- [16] ZHOU B, CHENG J, MAWANDIA A, et al. Tpm framework: a comprehensive kit for exploring applications with textile pressure mapping matrix[M]. *UBICOMM*, 2017.
- [17] XU Y, ZHANG J, ZHANG Q, et al. Vitpose: Simple vision transformer baselines for human pose estimation[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 38571-38584.
- [18] LUO Y, LI Y, FOSHEY M, et al. Intelligent carpet: Inferring 3d human pose from tactile signals[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021: 11255-11265.
- [19] CLEVER H M, KAPUSTA A, PARK D, et al. 3d human pose estimation on a configurable bed from a pressure image[C]//*2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2018: 54-61.
- [20] LUO Y, LI Y, SHARMA P, et al. Learning human-environment interactions using conformal tactile textiles[J]. *Nature Electronics*, 2021, 4(3): 193-201.
- [21] GUO W, LIU X, LU C, et al. Pifall: A pressure insole-based fall detection system for the elderly using resnet3d[J]. *Electronics*, 2024, 13(6): 1066.
- [22] XU G, WAN Q, DENG W, et al. Smart-sleeve: A wearable textile pressure sensor array for human activity recognition[J]. *Sensors*, 2022, 22(5): 1702.
- [23] ONOSE R, HARASAWA Y, ENOKIBORI Y, et al. Textile sensor-based visualization to enhance skills to understand the body-pressure distribution for pressure ulcer prevention[C]// *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*. 2018: 194-197.
- [24] ZHOU Y, BARNES C, LU J, et al. On the continuity of rotation representations in neural networks[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019: 5745-5753.
- [25] MEHTA D, SRIDHAR S, SOTNYCHENKO O, et al. Vnect: Real-time 3d human pose estimation with a single rgb camera[J]. *Acm transactions on graphics (tog)*, 2017, 36(4): 1-14.
- [26] GONG J, FOO L G, FAN Z, et al. Diffpose: Toward more reliable 3d pose estimation[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023:

- 13041-13051.
- [27] LI J, XU C, CHEN Z, et al. Hybrik: A hybrid analytical-neural inverse kinematics solution for 3d human pose and shape estimation[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 3383-3393.
 - [28] TU H, WANG C, ZENG W. Voxelpose: Towards multi-camera 3d human pose estimation in wild environment[C]//Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part I 16. Springer, 2020: 197-212.
 - [29] ZHANG J, CAI Y, YAN S, et al. Direct multi-view multi-person 3d pose estimation[J]. Advances in Neural Information Processing Systems, 2021, 34: 13153-13164.
 - [30] MARTÍNEZ-GONZÁLEZ A, VILLAMIZAR M, CANÉVET O, et al. Real-time convolutional networks for depth-based human pose estimation[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 41-47.
 - [31] JIANG W, XUE H, MIAO C, et al. Towards 3d human pose construction using wifi[C]//Proceedings of the 26th Annual International Conference on Mobile Computing and Networking. 2020: 1-14.
 - [32] REN Y, WANG Z, WANG Y, et al. Gopose: 3d human pose estimation using wifi[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2022, 6 (2): 1-25.
 - [33] HUANG Y, KAUFMANN M, AKSAN E, et al. Deep inertial poser: Learning to reconstruct human pose from sparse inertial measurements in real time[J]. ACM Transactions on Graphics (TOG), 2018, 37(6): 1-15.
 - [34] YI X, ZHOU Y, XU F. Transpose: Real-time 3d human translation and pose estimation with six inertial sensors[J]. ACM Transactions on Graphics (TOG), 2021, 40(4): 1-13.
 - [35] VON MARCARD T, ROSENHAHN B, BLACK M J, et al. Sparse inertial poser: Automatic 3d human pose estimation from sparse imus[C]//Computer graphics forum: volume 36. Wiley Online Library, 2017: 349-360.
 - [36] MOLLYN V, ARAKAWA R, GOEL M, et al. Imuposer: Full-body pose estimation using imus in phones, watches, and earbuds[C]//Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems. 2023: 1-12.
 - [37] HWANG D H, ASO K, YUAN Y, et al. Monoeye: Multimodal human motion capture system using a single ultra-wide fisheye camera[C]//Proceedings of the 33rd Annual ACM Symposium on User Interface Software and Technology. 2020: 98-111.
 - [38] ZHOU B, GEISLER D, FAULHABER M, et al. Mocapose: Motion capturing with textile-integrated capacitive sensors in loose-fitting smart garments[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2023, 7(1): 1-40.

- [39] ATALAY O. Textile-based, interdigital, capacitive, soft-strain sensor for wearable applications [J]. *Materials*, 2018, 11(5): 768.
- [40] BIAN S, REY V F, HEVESI P, et al. Passive capacitive based approach for full body gym workout recognition and counting[C]//2019 IEEE International Conference on Pervasive Computing and Communications (PerCom). IEEE, 2019: 1-10.
- [41] BELLO H, ZHOU B, SUH S, et al. Mocapaci: Posture and gesture detection in loose garments using textile cables as capacitive antennas[C]//Proceedings of the 2021 ACM International Symposium on Wearable Computers. 2021: 78-83.
- [42] ZHENG E, MAI J, LIU Y, et al. Forearm motion recognition with noncontact capacitive sensing[J]. *Frontiers in Neurorobotics*, 2018, 12: 47.
- [43] SUNDHOLM M, CHENG J, ZHOU B, et al. Smart-mat: Recognizing and counting gym exercises with low-cost resistive pressure sensing matrix[C]//Proceedings of the 2014 ACM international joint conference on pervasive and ubiquitous computing. 2014: 373-382.
- [44] MEYER J, ARNRICH B, SCHUMM J, et al. Design and modeling of a textile pressure sensor for sitting posture classification[J]. *IEEE Sensors Journal*, 2010, 10(8): 1391-1398.
- [45] ZHOU B, KOERGER H, WIRTH M, et al. Smart soccer shoe: monitoring foot-ball interaction with shoe integrated textile pressure sensor matrix[C]//Proceedings of the 2016 ACM International Symposium on Wearable Computers. 2016: 64-71.
- [46] ZHANG W, TASHAKORI A, JIANG Z, et al. Intelligent knee sleeves: A real-time multi-modal dataset for 3d lower body motion estimation using smart textile[J]. *Advances in Neural Information Processing Systems*, 2024, 36.
- [47] ZHANG Q, LI Y, LUO Y, et al. Dynamic modeling of hand-object interactions via tactile sensing[C]//2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2021: 2874-2881.
- [48] LIANG Z, ZHANG D, XU G, et al. Smart garment: A long-term feasible, whole-body textile pressure sensing system[J]. *IEEE Sensors Journal*, 2023.
- [49] WU Z, WAN Q, ZHAO M, et al. Massnet: A deep learning approach for body weight extraction from a single pressure image[C]//2023 IEEE International Conference on Pervasive Computing and Communications (PerCom). IEEE, 2023: 180-189.
- [50] DAVOODNIA V, SLINOWSKY M, ETEMAD A. Deep multitask learning for pervasive bmi estimation and identity recognition in smart beds[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2020: 1-15.
- [51] ENOKIBORI Y, MASE K. Data augmentation to build high performance dnn for in-bed posture classification[J]. *Journal of Information Processing*, 2018, 26: 718-727.
- [52] HUDEC R, MATÚŠKA S, KAMENCAY P, et al. A smart iot system for detecting the position

- of a lying person using a novel textile pressure sensor[J]. *Sensors*, 2020, 21(1): 206.
- [53] CARBONARO N, LAURINO M, ARCARISI L, et al. Textile-based pressure sensing matrix for in-bed monitoring of subject sleeping posture and breathing activity[J]. *Applied Sciences*, 2021, 11(6): 2552.
- [54] CASAS L, NAVAB N, DEMIRCI S. Patient 3d body pose estimation from pressure imaging [J]. *International journal of computer assisted radiology and surgery*, 2019, 14: 517-524.
- [55] DAVOODNIA V, ETEMAD A. Human pose estimation from ambiguous pressure recordings with spatio-temporal masked transformers[C]//ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2023: 1-5.
- [56] DAVOODNIA V, GHORBANI S, ETEMAD A. In-bed pressure-based pose estimation using image space representation learning[C]//ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2021: 3965-3969.
- [57] MULLER L, OSMAN A A, TANG S, et al. On self-contact and human pose[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 9990-9999.
- [58] CLEVER H M, ERICKSON Z, KAPUSTA A, et al. Bodies at rest: 3d human pose and shape estimation from a pressure image using synthetic data[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 6215-6224.