

## 髋关节角多模型贝叶斯动态估计

张志强<sup>①②</sup> 黄志蓓<sup>①</sup> 吴健康<sup>\*①</sup>

<sup>①</sup>(中国科学院研究生院与自动化所传感网络与应用联合研究中心 北京 100190)

<sup>②</sup>(英国帝国理工学院计算机系 伦敦 SW7 2AZ)

**摘要:** 步态分析在健康监测等领域中有着广泛的应用,精确估计髋关节角是步态分析的前提。但是大腿运动的高度非线性和不确定性,以及微型传感器测量噪声的不稳定性等诸多因素,基于微型惯性传感器的髋关节角精确估计面临着巨大的挑战。该文提出利用混合动态贝叶斯网络、多运动模型和噪声模型对髋关节角的非线性变化和测量噪声的改变进行建模,然后基于穿戴在大腿上的微型加速度传感器获得的测量值,通过高斯粒子滤波算法估计髋关节角。实验结果表明该方法能够有效提高髋关节角的估计精度。

**关键词:** 贝叶斯网络, 粒子滤波, 髋关节角估计

中图分类号: TN911.72

文献标识码: A

文章编号: 1009-5896(2011) 04-0775-06

DOI: 10.3724/SP.J.1146.2010.00885

## Ambulatory Hip Angle Estimation Using Multiple Model Hybrid Dynamic Bayesian Networks

Zhang Zhi-qiang<sup>①②</sup> Huang Zhi-pei<sup>①</sup> Wu Jian-kang<sup>①</sup>

<sup>①</sup>(Sensor Network and Application Research Center (SNARC), Institute of Automation and Graduate University, Chinese Academy of Sciences, Beijing 100190, China)

<sup>②</sup>(Department of Computing, Imperial College, London UK SW7 2AZ)

**Abstract:** Hip angle is a major parameter in gait analysis while gait analysis plays important role in healthcare, animation and other applications. Accurate estimation of hip angle using wearable inertial sensors in ambulatory environment remains a challenge, this is mainly because (1) the non-linear nature of thigh movement has not been well addressed, and (2) the variation of micro-inertial sensor measurement noise has not been studied yet. We propose to use Hybrid Dynamic Bayesian Network (HDBN) and multiple motion models and multiple noise models to model the non-linear hip angle dynamics and variation of measurement noise levels. Gaussian Particle Filter (GPF) is employed to estimate the hip angle during gait cycles from the measurements of accelerometers that are attached to the thighs. The experimental results show that the proposed method can achieve significant accuracy improvement over the previous work on the ambulatory hip angle estimation.

**Key words:** Bayesian network; Particle filter; Hip angle estimation

### 1 引言

近几年,精确评估髋关节角的变化及其在人体健康监测等领域的应用越来越受到研究者的关注。越来越多的证据显示,可以通过评估髋关节角的变化来识别帕金森症以及早期诊断老年痴呆症<sup>[1,2]</sup>。然而现有的步态分析系统都是基于多个高精度的摄像机,如 Vicon<sup>[3]</sup>等。这类系统需要测试者身着带有反射标记的特制服装,通过从摄像机捕捉的图像中计

算标记的位置来估计人体运动。这类系统具有较高的精度,已被广泛应用于数字电影特技中,但其造价非常昂贵,且必须被装配在专用实验室中<sup>[4]</sup>。随着无线传感网络的发展,基于惯性传感器的步态分析方法在近几年也发展起来并成为一个新兴的研究课题。国际上的一些先驱的工作主要都是基于运动学和运动力学的分析,如 Schepers<sup>[5]</sup>通过对加速度和角速度积分来估计小腿屈伸角和髋关节角,但是这种方法往往会产生漂移; Dejnabadi 等人<sup>[6]</sup>通过加速计和陀螺仪来估计关节角,避免了因为积分操作而产生漂移,但是这种方法需要建立下肢各个关节运动的数学关系; Favre 等人<sup>[7]</sup>提出利用融合 3 维加速计和陀螺仪的方法来去除漂移。上述的方法都是基于

2010-08-19收到, 2010-11-22改回

中国新加坡数字媒体研究院(China-Singapore Institute of Digital Media, CSIDM-200802)和国家自然科学基金重点项目(60932001)资助课题

\*通信作者: 吴健康 jkwu@gucas.ac.cn

运动学和运动动力学的分析,他们只考虑了人体下肢的结构信息,而没有考虑人体下肢运动的时间相关性,更没有考虑传感器噪声的变化。Dong 等人<sup>[9]</sup>考虑了髋关节角变化的连续性,并且假设其变化是线性的,然后使用卡尔曼滤波(Kalman Filter, KF)对其进行估计,但是由于线性变化的假设,导致了估计误差比较大。文献[9]引入隐式马尔可夫(Hidden Markov Model, HMM)模型来检测步态周期中的关键事件,并更新 KF 估计的结果。这种方法虽然取得了不错的效果,但是它还是不能完全建模髋关节角变化的非线性,同时,他们也没有考虑传感器噪声的变化。

在充分认识到大腿运动的非线性和微型传感器的测量噪声的变化性之后,本文提出:(1)利用多个线性模型建模运动的非线性,简称为多运动模型(Multiple Dynamic Models, MDM);(2)利用多个噪声级别建模测量噪声的变化,简称为多噪声模型(Multiple Noise Models, MNM)。我们将步态周期划分为4个阶段,每个阶段的运动用一个模型来建模,测量噪声用一个高斯噪声来建模。在大腿运动的过程中,每个时刻只选择一个运动模型和一个噪声模型。4个运动模型和噪声模型之间的转换利用状态转移矩阵来描述。MDM, MNM 及其转换总体上可以用一个混合动态贝叶斯网络(Hybrid Dynamic Bayesian Network, HDBN)来表示。HDBN 同我们所熟悉条件线性高斯模型(Conditional Linear Gaussian Model, CLGM),交换卡尔曼滤波<sup>[10]</sup>(Switching Kalman Filters, SKFs)或者是跳跃马尔可夫线性系统<sup>[11]</sup>(Jump Markov Linear System, JMLS)比较相似。Gerome 等人<sup>[11]</sup>和 Pang 等人<sup>[12]</sup>都是利用马尔可夫链蒙特卡罗(Markov Chain Monte Carlo, MCMC)方法来进行参数和状态估计。但是这些方法只适用于线性和分段线性的情况,它要求状态方程和测量方程在任意时刻都是线性的。但是髋关节角的测量方程在任意时刻都是非线性的,故本文使用 HDBN 来表示髋关节角的估计问题,并使用高斯粒子滤波<sup>[13]</sup>(Gaussian Particle Filter, GPF)算法求解。GPF 只是在离散状态空间(一个步态周期的4个阶段)中采样,然后利用 Unscented 卡尔曼滤波器(Unscented Kalman Filter, UKF)来估计连续状态空间的变量,如髋关节角度等。通过 HDBN 表示和 GPF 迭代运算,能够很好地建模髋关节角变化的非线性、测量的非线性以及测量噪声的变化性,同时提高估计精度。

## 2 步态周期的划分与特性

步态周期通常被定义为左脚或右脚连续两次触

地之间的时间间隔。根据髋关节角的变化及其变化率,一个典型的步态周期可以分成4个阶段<sup>[9,14]</sup>:

阶段1是脚尖离地(toe off):目标脚抬起,离开地面的瞬间,它是一个步态周期的起点。在这个阶段中,髋关节角速度首先降为0,此时髋关节角达到最小值,然后髋关节角速度反向并上升。

阶段2是前摆(swing forward):目标腿向前摆动,在这个阶段中,髋关节角一直上升,髋关节角速度缓慢上升直至峰值,然后下降。

阶段3是脚跟触地(heel strike):目标脚跟接触地面的瞬间,在这个阶段中,髋关节角速度首先降为0,此时髋关节角达到最大值,然后髋关节角速度反向并上升。

阶段4是腿支撑(weight support):目标脚支撑人体,使得另外一只脚向前摆动。在这个阶段中,髋关节角一直下降,髋关节角速度缓慢上升直至峰值,然后下降。

在上面的讨论中,髋关节角速度的变化指其幅度的变化。

如图1(a)所示,上述的步态周期的4个阶段周期性的重复:脚尖离地(阶段1)→前摆(阶段2)→脚跟触地(阶段3)→腿支撑(阶段4)→脚尖离地(阶段1)。这4个阶段构成了一个马尔可夫过程,其状态转移矩阵可以描述为

$$T = \begin{bmatrix} p_{11} & p_{12} & 0 & 0 \\ 0 & p_{22} & p_{23} & 0 \\ 0 & 0 & p_{33} & p_{34} \\ p_{41} & 0 & 0 & p_{44} \end{bmatrix} \quad (1)$$

其中  $p_{mn}$  表示从步态阶段  $m$  转移到步态阶段  $n$  的概率。




图1 步态周期及髋关节角

### 3 多运动模型和多噪声模型

本文选择了相对简单的二轴加速计来进行 2 维步态分析。因为: (1)这类系统非常便宜, 可以广泛使用; (2)这类系统在方法学研究上具有实现相对简单的优点, 其研究成果可以方便地推广到较为复杂的 3 维和多种传感器系统中去。为了估计髌关节角度的变化, 2 维加速度传感器被穿戴在大腿外侧离髌关节 30 cm 的地方, 如图 2 所示, 加速计分别测量  $x$  轴和  $y$  轴的加速度  $c$  和  $d$ 。由于人体运动过程中, 躯干几乎保持垂直, 因为可以简化髌关节角的定义为  $y$  轴和重力方向的角度  $\theta$ 。髌关节角的变化率(角速度)相应可以定义为  $\nu = d\theta/dt$ 。图中的变量  $a$  和  $b$  分别代表水平方向加速度和垂直方向加速度。




图 2 髌关节角估计中涉及的参数和测量

#### 3.1 状态方程和多运动模型设计

在前摆和腿支撑阶段, 大腿运动相对稳定; 大腿摆动角速度变化率可以由系统噪声来表示。因此我们可以为髌关节角的变化建立如下的 CV 运动模型:

$$\mathbf{X}_t = \mathbf{A}\mathbf{X}_{t-1} + \mathbf{W} \quad (2)$$

其中  $\mathbf{X}_t = [\theta_t \ \nu_t \ a_t \ b_t]^T$  是  $t$  时刻的状态变量。  $\mathbf{A} = \begin{bmatrix} 1 & t_s & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$  是系统状态矩阵。其中  $t_s$  是采样间隔,

本文中设置成 0.04 s。在式(2)中,  $\mathbf{W} = [t_s^2 w_\theta \ t_s w_\nu \ w_a \ w_b]^T$  是系统噪声。其中  $w_\theta$  是髌关节角度变化的白加速噪声, 其均值和方差分别是 0 和  $Q_\theta$ 。  $w_a$  和  $w_b$  分别描述髌关节角度变化过程中水平方向和垂直方向的加速度的变化, 它们同样被假设为 0 均值的高斯白噪声, 且方差分别为  $Q_a$  和  $Q_b$ 。尽管  $\mathbf{W}$  不会是一个简单的高斯分布的噪声, 但是仍然可以用高斯混合来近似表示。这里只考虑高斯混合中的最主要

成分, 依然假设  $\mathbf{W}$  是 0 均值的高斯分布的噪声。

在脚尖离地和脚跟触地阶段, 由于人体腿部肌肉产生的前摆力和脚跟撞击地面, 髌关节角速率变化剧烈, 它的方程不再满足式(2)的描述, 需要重新设计不同的运动模型。由于这两个阶段的持续时间非常的短暂, 髌关节角的变化不大, 因此可以用一个简单的 CV 模型来建模其变化。为了克服肌肉的影响, 引入控制变量  $\mathbf{u} = [u_\theta \ u_\nu]^T$ 。其中  $(u_\theta \ u_\nu)$  是髌关节角及其变化率在这两个阶段的概率密度函数的均值。因此, 新的状态方程可以写成:

$$\mathbf{X}_k = \mathbf{A}'\mathbf{X}_{k-1} + \mathbf{B}\mathbf{u} + \mathbf{W}' \quad (3)$$

其中  $\mathbf{A}' = \begin{bmatrix} 1 - K_\theta & (1 - K_\theta)t_s & 0 & 0 \\ 0 & 1 - K_\nu & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{B} = \begin{bmatrix} K_\theta & 0 \\ 0 & K_\nu \\ 0 & 0 \\ 0 & 0 \end{bmatrix}$ 。由

于这两个阶段的持续时间非常的短暂, 但髌关节角的变化率迅速归零, 控制变量  $u_\theta$  和  $u_\nu$  的作用保证了髌关节角只在一个小范围内变化, 并且变化的速率接近 0, 因此我们将  $u_\nu$  设置成 0。在式(3)中  $K_\theta$  和  $K_\nu$  都是大于 0 小于 1 的常数;  $\mathbf{W}'$  和式(2)中的  $\mathbf{W}$  具有相同的含义。

#### 3.2 测量方程和多噪声模型设计

对于一个步态周期的各个阶段来说, 测量方程的形式都是一样的。对于测量  $c$  和  $d$  可以和状态变量建立如下的方程:

$$\left. \begin{aligned} c_k &= -g \sin \theta_k - a_k \cos \theta_k + b_k \sin \theta_k + w_c \\ d_k &= -g \cos \theta_k + a_k \sin \theta_k + b_k \cos \theta_k - r\nu_k^2 + w_d \end{aligned} \right\} \quad (4)$$

或者以函数的形式

$$\mathbf{Y}_k = h(\mathbf{X}_k) + \mathbf{V} \quad (5)$$

其中  $\mathbf{Y}_k = [c_k \ d_k]^T$  是测量向量;  $\mathbf{V} = [w_c \ w_d]^T$  是测量误差;  $r$  是传感器到髌关节的距离(本文设置为 0.3 m);  $g$  是重力加速度。同时假设  $\mathbf{V}$  为 0 均值高斯白噪声:

$$P(w_c \ w_d) \sim N(0 \ \mathbf{R}) \quad (6)$$

其中  $\mathbf{R} = \begin{bmatrix} R_c & 0 \\ 0 & R_d \end{bmatrix}$  是协方差矩阵。

#### 3.3 混合状态估计

在 3.1 节和 3.2 节中, 我们已经为步态周期的各个阶段建立状态方程和测量方程。将其与 4 个步态阶段构成的马尔可夫链结合起来就可以用如图 3 所示的 HDBN 表示, 其中  $S$  代表步态阶段,  $\mathbf{X}$  是连续的状态变量,  $\mathbf{Y}$  是观测变量。在 HDBN 中, 操作模式节点表示步态阶段, 因此可以综合为如下的状态




图3 MDM和MNM的HDBN表示

方程:

$$S_t \sim p(S_t | S_{t-1}) \quad (7a)$$

$$\mathbf{X}_t = \mathbf{A}(S_t)\mathbf{X}_{t-1} + \mathbf{B}(S_t)\mathbf{u} + \mathbf{W}(S_t) \quad (7b)$$

$$\mathbf{Y}_t = h(\mathbf{X}_t) + \mathbf{V}(S_t) \quad (7c)$$

其中  $S_t \in \{1, 2, 3, 4\}$  表示一个周期的4个步态阶段。由于  $S_t$  起着模型旋转的作用, 状态方程(7b)和(7c)中的测量噪声都根据  $S_t$  来进行选取。

通常计算最大后验(Maximum A Posterior, MAP)准则从加速度计的测量中估计髋关节角。由于该估计的复杂性, 我们首先计算后验概率  $p(S_{0:t}, \mathbf{X}_{0:t} | \mathbf{Y}_{0:t})$ , 然后对其求取边缘分布(marginalized distribution)  $p(\mathbf{X}_{0:t} | \mathbf{Y}_{0:t})$ , 其中  $(S, \mathbf{X})$  被称为混合状态(hybrid state)。后验概率  $p(S_{0:t}, \mathbf{X}_{0:t} | \mathbf{Y}_{0:t})$  有如下的展开形式:

$$\begin{aligned} p(S_{0:t}, \mathbf{X}_{0:t} | \mathbf{Y}_{0:t}) \\ = p(S_{0:t-1}, \mathbf{X}_{0:t-1} | \mathbf{Y}_{0:t-1}) \\ \cdot \frac{p(\mathbf{Y}_t | \mathbf{X}_t, S_t)p(\mathbf{X}_t | \mathbf{X}_{t-1}, S_t)p(S_t | S_{t-1})}{p(\mathbf{Y}_t | \mathbf{Y}_{1:t-1})} \end{aligned} \quad (8)$$

显然, 式(8)没有解析解, 传统的求解方法利用蒙特卡罗的方法对  $(S_t, \mathbf{X}_t)$  进行联合采样, 但是需要的粒子数巨大, 导致运算复杂。后验概率密度函数  $p(S_{0:t}, \mathbf{X}_{0:t} | \mathbf{Y}_{1:t})$  还可以分解为  $p(S_{0:t}, \mathbf{X}_{0:t} | \mathbf{Y}_{0:t}) = p(\mathbf{X}_{0:t} | \mathbf{Y}_{0:t}, S_{0:t})p(S_{0:t} | \mathbf{Y}_{0:t})$ , 其中  $p(\mathbf{X}_{0:t} | \mathbf{Y}_{0:t}, S_{0:t})$  是一个近似高斯分布,  $p(S_{0:t} | \mathbf{Y}_{1:t})$  又存在如下的分解:

$$\begin{aligned} p(S_{0:t} | \mathbf{Y}_{0:t}) = p(S_{0:t-1} | \mathbf{Y}_{0:t-1}) \\ \cdot \frac{p(S_t | S_{t-1})p(\mathbf{Y}_t | \mathbf{Y}_{1:t-1}, S_{0:t})}{p(\mathbf{Y}_t | \mathbf{Y}_{1:t-1})} \end{aligned} \quad (9)$$

显然式(9)和式(8)一样, 不存在解析解, 同样需要通过采样的方法来求解。假如我们有一组关于  $S_t$  的采样点  $\{S_{0:t}^{(i)}, w_t^{(i)}\}_{i=1}^N$ ,  $S_t$  的后验概率可以表示为

$$\hat{P}_N(S_{0:t} | \mathbf{Y}_{0:t}) = \sum_{i=1}^N w_t^{(i)} \delta_{S_{0:t}^i}(S_{0:t}^i) \quad (10)$$

其中  $\delta_{S_{0:t}^i}(S_{0:t}^i)$  是一个 Dirac-delta 函数;  $N$  是粒子点个数。因此,  $\mathbf{X}_{0:t}$  的后验概率可以用一个高斯混合来表示

$$\begin{aligned} \hat{P}_N(\mathbf{X}_{0:t} | \mathbf{Y}_{0:t}) &= \int p(\mathbf{X}_{0:t} | \mathbf{Y}_{1:t}, S_{0:t}) dP(S_{0:t} | \mathbf{Y}_{0:t}) \\ &= \sum_{i=1}^N w_t^{(i)} p(\mathbf{X}_{0:t} | \mathbf{Y}_{1:t}, S_{0:t}^{(i)}) \end{aligned} \quad (11)$$

上面的计算可以总结为一高斯粒子滤波算法: 对  $S_t$  进行采样, 然后可以通过 Unscented 卡尔曼滤波器来计算  $p(\mathbf{X}_{0:t} | \mathbf{Y}_{0:t}, S_{0:t})$ , 从而计算后验概率  $p(\mathbf{X}_{0:t} | \mathbf{Y}_{0:t})$ 。

## 4 实验结果及分析

为了验证本文提出的 HDBN 和 GPF 方法, 我们主要比较以下4个不同方法的实验结果: (1)简单的 EKF/UKF 和混合的 HMM/EKF; (2)只考虑 MNM, 不考虑 MDM; (3)只考虑 MDM, 不考虑 MNM; (4)同时考虑 MDM 和 MNM。

### 4.1 实验环境

实验中, 测试者处于一个开放式的环境中。如图2所示, 测试者在大腿外侧离髋关节 30 cm 的地方穿戴一个微型加速计, 同时穿戴一个白色条状的标签。在测试开始前, 测试者保持静止站立状, 用于和摄像机进行校准。在测试者运动的过程中, 加速计测量被实时传回 PC, 同时用摄像机记录人体的运动。在视频中, 髋关节角度被定义为条状标签与垂直方向的夹角, 通过从视频的各帧图像中手动测量而得到。在进行髋关节角估计性能分析的过程中, 视频测量的髋关节角度作为基准使用。

### 4.2 髋关节角估计性能分析

图4-图7给出了实验结果。利用文献[9]中传统的方法来跟踪髋关节角的结果在图4中给出。对于 EKF, UKF 和混合的 HMM/EKF 方法, 他们的平均估计误差分别是  $4.54^\circ$ ,  $4.46^\circ$  和  $3.85^\circ$ 。尽管混合的 HMM/EKF 方法的效果要稍好于传统的 EKF 和 UKF, UKF 的跟踪效果好于 EKF, 但是这3种方法跟踪的结果和真值之间都有着巨大的偏差, 这主要是因为:

(1)在脚尖离地和脚跟触地阶段, 由于人体肌肉产生了比较大的驱动力, 这些驱动力在测量方程中以大噪声的形式表征。在前摆和腿支撑阶段, 人体肌肉产生的驱动力比较小, 从而测量噪声也比较小, 但是由于测量方程中的噪声模型假定唯一固定的噪声级别, 显然这种假设不能很好地反应测量噪声的变化, 导致了比较明显的估计偏差。

(2)在传统的方程中使用的是线性的运动模型。在脚尖离地和脚跟触地阶段, 因为髋关节角速度反向, 因此需要KF的多次迭代才能收敛到真实值, 从而导致了比较大的估计误差。另一方面, 尽管混合的HMM/EKF利用HMM来检测特定的步态事件从




图 4 利用传统的方法估计髋关节角




图 5 只利用 MNM 估计髋关节角

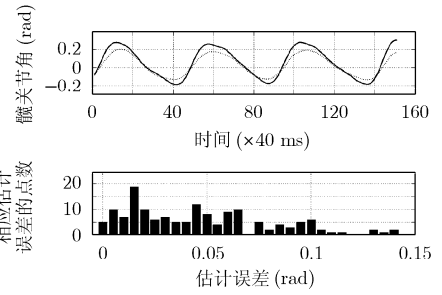


图 6 只利用 MDM 估计髋关节角

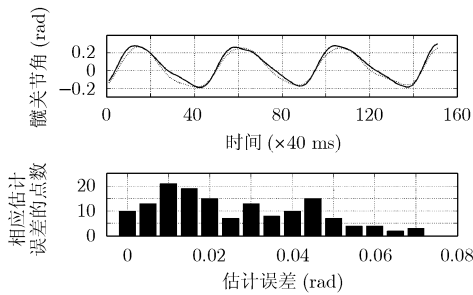


图 7 同时利用MDM和MNM估计髋关节角

而更新估计结果，但是这种方法也不能很好地建模髋关节角变化的非线性。

总之，由于传统的方法假定了线性运动方程和单一噪声级别，这些假设与实际情况不符，导致了比较大的估计误差。

为了验证本文的方法，我们将验证单独使用 MNM, MDM 和同时使用 MNM 和 MDM 的估计性能，并分别用图 5, 图 6 和图 7 来表示。保持所有时刻的运动模型不变，引入多噪声模型，以验证多运动模型的有效性。如图 5 所示，只使用 MNM 来估计髋关节角的平均估计误差为 4.19°，其与真值之间有着比较大的偏差。由于使用了多噪声测量模型，导致在脚尖离地和脚跟触地阶段的估计好于传统的 EKF 或 UKF。由于在摆腿和腿支撑阶段的运动特性完全与脚尖离地和脚跟触地阶段不同，因此需要不同的运动模型来表征其运动，以此达到比较好的跟踪效果。

接下来通过使用多运动模型和单一噪声级别来估计髋关节角，以此来验证多噪声模型的效果。实验中，将噪声方程设定为  $R = \text{diag}(5, 5)$ ，得到的估计结果如图 6 所示。其平均估计误差为 2.57°，图 6 同时给出了其估计误差直方图。从图中我们可以看到，在摆腿和腿支撑的阶段，估计值和真值之间的差别很小。最大的估计误差存在于脚尖离地和脚跟触地阶段，这是因为：(1)由于肌肉作用引起的大测

量噪声和小噪声的交替变化，简单的高斯假设不能够建模测量噪声的变化；(2)为了运动模型的简单，我们没有考虑这两个阶段的加速和减速过程，因此同样引入了部分的估计误差。

最后验证了同时使用多噪声模型和多运动模型的情况。如图 7 所示，估计值非常贴近于真值，平均估计误差为 1.52°，这是现阶段只有单个传感器进行估计的最高精度。这主要是因为本文使用了多运动模型和多噪声模型，它们能够：(1)自适应地进行模型转换，在不同的步态阶段选择不同的运动模型；(2)有效地解决了传感器测量噪声的变化问题，通过使用高斯混合模型来建模不同级别的噪声，并根据噪声的强度，自适应的调整高斯混合的权重。

此外，在估计髋关节角的过程中，我们也注意到了方差的变化：方差在估计的初始阶段，迅速下降，经过一段时间后，基本达到收敛。这表明了我们的方法能够有效的估计髋关节角度。

### 4.3 讨论

若测试者增加走路的速度，本文方法的估计性能有细微的下降。这是因为随着走路速度的增加，测量噪声整体增加所致。另外，对其它 3 个不同身高不同体重不同年龄的测试者进行了相同的实验，结果表明，平均估计误差都在  $-2^\circ \sim 2^\circ$  之间。

对于步态周期各个阶段的控制变量  $u$  需要进行实时更新，以此来适应人体运动速度的变化。每当一个步态周期处理完后，控制变量可以更新为  $u = (1 - \rho)u + \rho u_{\text{new}}$ 。其中  $u_{\text{new}}$  是根据前一个步态周期估计的控制变量的值； $\rho$  是 0 和 1 之间的常数，本文取为 0.1。

由于高斯粒子滤波(500 个粒子点)的计算量很大，不能实时地估计髋关节角。我们系统地比较了 50 个，100 个，200 个，500 个和 1000 个粒子点的估计效果，分析表明：(1)随着粒子点的增加，估计误差变得越来越小；(2)50 个粒子点的估计误差相对于 1000 个点的估计误差大约有 5% 的增加，这也是

高斯粒子滤波相对于传统粒子滤波的一大优势(需要的粒子点比较少)。我们在 PC(Pentium (R) 4/2.8 GHz, 2G RAM)上利用 C 语言实现了文中的算法。当采用 200 个粒子点的时候, 文中的算法是可以进行实时运算的。虽然对于 500 个粒子点, 现阶段暂时还不能实现实时运算, 但是相信随着计算机运算速度的发展, 这个目标应该在不久的将来就能够达成。

以后的工作主要包括根据测量的大腿加速度来提取特征向量并用于步态阶段的检测, 自适应地选择唯一的运动模型和噪声模型, 从而降低计算量以实现髋关节角的实时估计。本文的主要目标是验证在髋关节角的估计过程中多模型的有效性, 实验也已经证明了其优越性。由于本文选择了多个线性模型的组合来刻画大腿运动的非线性特性, 这相对于单个线性模型有了巨大的进步, 但是能否需要进一步寻找一个非线性模型来准确刻画大腿运动的非线性特性, 这个也是需要进一步研究的问题。另一方面, 该算法只验证了正常步态周期髋关节角度变化的估计, 接下来, 我们将进一步优化该算法, 并应用于异常步态的检测。

## 5 结束语

本文介绍了一种多模型髋关节角估计的方法。文中首先分析了步态周期 4 个阶段中的髋关节运动特性, 然后为每一个阶段设计了相应的运动模型和噪声模型, 并用混合动态贝叶斯网络表示。在贝叶斯网络的框架下, 通过高斯粒子滤波算法从穿戴在大腿外侧的加速计测量中估计髋关节角度。实验结果表明, 对于不同的测试者, 本文的方法都能够有效提高髋关节角的估计精度。

## 参考文献

- [1] Baechlin M, Plotnik M, and Roggen D, *et al.* Wearable assistant for Parkinson's disease patients with the freezing of gait symptom [J]. *IEEE Transactions on Information Technology in Biomedicine*, 2010, 14(2): 436-446.
- [2] Wittwer J E, Webster K E, and Menz H B. A longitudinal study of measures of walking in people with alzheimer's disease [J]. *Gait & Posture*, 2010, 32(1): 113-117.
- [3] Wong A Y C, Sangeux M, and Baker R. Calculation of joint moments following foot contact across two force plates [J]. *Gait & Posture*, 2010, 31(2): 292-293.
- [4] Vlasic D, Adelsberger R, and Vannucci G, *et al.* Practical motion capture in everyday surroundings [J]. *ACM Transactions on Graphics*, 2007, 26(3): 35-44.
- [5] Schepers H M. Ambulatory assessment of human body kinematics and kinetics [D]. [Ph.D. dissertation], University of Twente, 2009.
- [6] Dejnabadi H, Jolles B M, and Aminian K. A new approach for quantitative analysis of inter-joint coordination during gait [J]. *IEEE Transactions on Biomedical Engineering*, 2008, 55(2): 755-764.
- [7] Favre J, Jolles B M, Siegrist O, and Aminian K. Quaternion-based fusion of gyroscopes and accelerometers to improve 3D angle measurement [J]. *Electronics Letters*, 2006, 42(11): 612-614.
- [8] Dong L, Wu J K, and Bao X M. Tracking of thigh flexion angle during gait cycles in an ambulatory activity monitoring sensor network [J]. *Acta Automatica Sinica*, 2006, 32(6): 938-946.
- [9] Dong L, Wu J K, and Bao X M. A hybrid HMM/Kalman filter for tracking hip angle in gait cycle [J]. *IEICE Transaction on Information and Systems*, 2006, 89(7): 2319-2323.
- [10] Olanrewajua M J, Huang B, and Artin Afacana. Online composition estimation and experiment validation of distillation processes with switching dynamics [J]. *Chemical Engineering Science*, 2010, 65(5): 1597-1608.
- [11] Geromel J C, Goncalves A P C, and Fioravanti A R. Dynamic output feedback control of discrete-time Markov jump linear systems through linear matrix inequalities[J]. *SIAM Journal on Control and Optimization*, 2009, 48(2): 573-593.
- [12] Pang S K, Nelson J D B, and Godsill S J, *et al.* Video tracking using dual-tree wavelet polar matching and rao-blackwellised particle filter [J]. *EURASIP Journal on Advances in Signal Processing*, 2009, DOI: 10.1155/20091620404.
- [13] Hutter F and Dearden R. The gaussian particle filter for diagnosis of non-linear systems [C]. Proceedings of the Fourteenth International Workshop on the Principles of Diagnosis, Washington DC, USA, 2003: 65-70.
- [14] Murray M, Drought A B, and Kory R C. Walking patterns of normal men [J]. *The Journal of Bone and Joint Surgery*, 1964, 46(2): 335-360.

张志强: 男, 1983年生, 博士后, 研究方向为传感器网络、信息融合。  
 黄志蓓: 女, 1973年生, 副教授, 研究方向为信息隐藏、多目标跟踪和信息融合。  
 吴健康: 男, 1947年生, 教授, 研究方向为传感器网络和虚拟现实技术等。