

基于渐进无迹卡尔曼滤波网络的人体肢体运动估计

杨旭升^{1,2} 王雪儿^{1,2} 汪鹏君³ 张文安^{1,2}

摘要 针对基于表面肌电信号 (Surface electromyography, sEMG) 的人体肢体运动估计建模困难的问题, 提出一种渐进无迹卡尔曼滤波网络 (Progressive unscented Kalman filter network, PUKF-net), 来实现降低肢体运动与 sEMG 量测的建模难度以及提高肢体运动估计精度的目的。首先, 设计深度神经网络从 sEMG 数据中学习肢体运动状态与 sEMG 量测之间的映射关系和噪声统计特性。其次, 采用渐进量测更新方法对先验状态估计进行修正, 减小运动估计的线性化误差, 提高 PUKF-net 模型的稳定性。通过结合深度神经网络和渐进卡尔曼滤波的优势, 使得 PUKF-net 具有良好的模型适应性和抗噪能力。最后, 设计基于 sEMG 的人体肢体运动估计实验, 验证了 PUKF-net 模型的有效性。相较于长短期记忆网络 (Long short-term memory, LSTM) 和其他卡尔曼滤波网络, PUKF-net 在肢体运动估计中的均方根误差 (Root mean square error, RMSE) 下降了 14.9%, 相关系数 R^2 提高了 5.1%。

关键词 卡尔曼滤波网络, 人体肢体运动估计, 表面肌电信号, 渐进无迹卡尔曼滤波

引用格式 杨旭升, 王雪儿, 汪鹏君, 张文安. 基于渐进无迹卡尔曼滤波网络的人体肢体运动估计. 自动化学报, 2023, 49(8): 1723–1731

DOI 10.16383/j.aas.c220523

Estimation of Human Limb Motion Based on Progressive Unscented Kalman Filter Network

YANG Xu-Sheng^{1,2} WANG Xue-Er^{1,2} WANG Peng-Jun³ ZHANG Wen-An^{1,2}

Abstract To solve the difficult modeling problem of human limb motion estimation based on surface electromyography (sEMG), a progressive unscented Kalman filter network (PUKF-net) is proposed to reduce the difficulty of modeling limb motion and sEMG measurements and improve the accuracy of limb motion estimation. Firstly, a deep neural network is designed to learn the mapping relationship between limb motion states and sEMG measurements and the statistical property of noise from sEMG data. Secondly, a progressive measurement update method is used to correct the priori state estimate for reducing the linearization error of motion estimation and improving the stability of the PUKF-net. By combining the advantages of deep neural network and progressive Kalman filter, the PUKF-net has good model adaptability and anti-noise capability. Finally, a human limb motion estimation experiment based on sEMG is designed to verify the validity of the PUKF-net. Compared with the long short-term memory (LSTM) and other Kalman filter network models, the root mean square error (RMSE) of PUKF-net in limb motion estimation has decreased by 14.9% and the correlation coefficient R^2 has increased by 5.1%.

Key words Kalman filter network, human limb motion estimation, surface electromyography (sEMG), progressive unscented Kalman filter

Citation Yang Xu-Sheng, Wang Xue-Er, Wang Peng-Jun, Zhang Wen-An. Estimation of human limb motion based on progressive unscented Kalman filter network. *Acta Automatica Sinica*, 2023, 49(8): 1723–1731

收稿日期 2022-06-24 录用日期 2023-01-11

Manuscript received June 24, 2022; accepted January 11, 2023
浙江省“尖兵”“领雁”研发攻关计划 (2022C03114), 国家自然科学基金 (62173305), 浙江省自然科学基金 (LD21F030002) 资助

Supported by Zhejiang Province “Jianbing” “Lingyan” Research and Development Project (2022C03114), National Natural Science Foundation of China (62173305), and Natural Science Foundation of Zhejiang Province (LD21F030002)

本文责任编辑 孙健

Recommended by Associate Editor SUN Jian

1. 浙江工业大学信息工程学院 杭州 310023 2. 浙江省嵌入式系统联合重点实验室 杭州 310023 3. 温州大学电气与电子工程学院 温州 325035

1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023 2. Zhejiang Provincial United Key Laboratory of Embedded Systems, Hangzhou 310023 3. College of Electrical and Electronic Engineering, Wenzhou University, Wenzhou 325035

表面肌电信号 (Surface electromyography, sEMG) 是动作电位沿着肌纤维方向传播引起的生物电信号, 可用于反映人体肌肉收缩、关节力矩等运动信息^[1]。由于非侵入、测量技术相对成熟等特点, sEMG 被广泛用于估计人体的运动状态和运动意图^[2], 在人机协作、智能假肢、康复医疗和运动评估等领域有重要的应用价值^[3-5]。

基于 sEMG 的人体运动估计中的重要问题之一, 即如何建立 sEMG 与人体运动之间的映射模型。其中, 生理学建模是一种常用的方法, 该方法从运动生理学和生物力学出发, 将 sEMG 转换为动力, 并依据关节动力学得出人体运动信息^[6]。生理学

模型符合运动生理规律且具有较好的可解释性, 但计算复杂且涉及大量不易测量的生理参数, 限制了该类模型的应用^[7]. 近年来, 随着深度学习技术的迅速发展, 深度神经网络逐渐成为人体运动估计领域中应用最为广泛的方法^[8-14]. 在基于 sEMG 的人体运动估计中, 深度学习模型设计的核心在于如何利用深度神经网络从 sEMG 数据中学习出 sEMG 与人体运动之间的映射关系. Lu 等^[15] 提出了一种堆叠卷积长短记忆网络 (Stacked convolutional and long-short term memory networks, Conv-LSTM) 用于人体下肢关节角度估计. Chai 等^[16] 结合长短记忆网络 (Long short-term memory, LSTM) 和离散时间归零神经算法的闭环控制模型来实现人体上肢运动意图的准确估计. 尽管这类方法取得了较好的准确性, 但深度神经网络作为一种“黑箱”模型含有大量不可见状态且可解释性欠缺, 限制了其估计性能的进一步提升^[17].

基于卡尔曼滤波的状态估计方法通过显式描述表示系统状态的转换关系, 具有良好的噪声处理能力. 为处理深度神经网络含有噪声的估计输出^[18-21], Zhang 等^[18] 设计 LSTM-UKF 算法, 利用 LSTM 网络提供量测预测值, 解决量测缺失引起的误差增大问题. Jondhale 等^[19] 利用无迹卡尔曼滤波 (Unscented Kalman filter, UKF) 进一步提高广义回归神经网络的估计精度. Lim 等^[20] 提出利用 TCN (Temporal convolutional network) 将各类信号合成分后辅助 UKF 进行状态估计的方法. 然而, 卡尔曼滤波方法的应用需要大量先验知识来设计人体运动模型和调整参数, 尤其是肌肉运动引起的 sEMG 与人体运动状态之间物理关系涉及大量复杂转换以及大量难以测量的生理学参数. 同时, sEMG 噪声的复杂性和人体运动的随机性又增加了人体运动估计的建模难度. 为了克服这些限制, 已有学者尝试将卡尔曼滤波与神经网络相结合, 从测量数据中使用神经网络来学习卡尔曼滤波参数^[17, 22-25]. Coskun 等^[22] 提出了 LSTM-KF (LSTM-based Kalman filter process), 用于处理任意黑盒估计器输出的含有噪声的人体姿态估计, 通过三个 LSTM 模块分别学习卡尔曼滤波的状态模型、观测模型以及噪声模型. Bao 等^[23] 提出了深度卡尔曼滤波网络 (Deep Kalman filter network, DKFN), 利用卷积神经网络 (Convolutional neural network, CNN) 提取 sEMG 高维特征后输入 LSTM-KF, DKFN 在 LSTM-KF 的基础上, 增加了一个 LSTM 模块用于学习卡尔曼增益. Zhao 等^[24] 提出学习卡尔曼网络 (Learning Kalman network, LKN), 由全连接层学习其状态模型和量测模型参数, 由 LSTM 模块学习得到卡尔曼增益.

这种结合深度神经网络的卡尔曼滤波方法称作卡尔曼滤波网络 (Kalman filter network, KFN). 通过结合深度学习与卡尔曼滤波的优势, KFN 具有较好的模型适应性和抗噪能力. 然而, 非线性的深度神经网络使得滤波过程中引入较大的线性化误差, 影响了 KFN 的估计精度和系统的稳定性^[26-27], 因此目前与卡尔曼滤波结合的神经网络结构较简单. 由于结构限制, KFN 的估计能力有限, 通常在其他估计模型之后用于进一步处理含有噪声的状态估计或高阶特征^[22-24].

针对以上问题, 本文提出了一种渐进无迹卡尔曼滤波网络 (Progressive unscented Kalman filter network, PUKF-net) 端到端地实现基于 sEMG 的人体运动状态估计, 其结构如图 1 所示. 首先, 根据人体运动过程建立非线性状态转移模型和量测模型, 设计了三个 LSTM 模块直接从 sEMG 数据中学习人体运动状态与 sEMG 量测的映射关系, 以及模型的噪声统计特性; 其次, 利用 UT (Unscented transformation) 变换和渐进量测更新方法减小线性化误差, 提高 PUKF-net 模型的稳定性; 最后, 通过实验采集肢体运动过程关节角度变化和相关肢体 sEMG, 验证了 PUKF-net 模型的有效性和优越性.

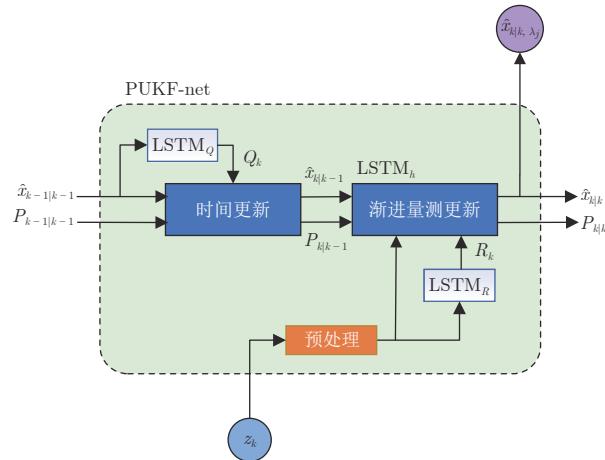


图 1 PUKF-net 结构
Fig. 1 Structure of PUKF-net

1 问题描述

sEMG 是一种反映肌群潜在变化的表征方式, 其有效信号频带范围为 10~500 Hz, 信号幅度一般为 0~5 mV. 基于 sEMG 的人体肢体运动状态估计的主要难点在于: 1) 人体运动涉及多块肌肉活动, sEMG 信号实际上是多层次肌肉活动引起的动作电位在皮肤表面叠加的结果; 2) 由于 sEMG 的非平稳、微弱等特性, 同时受体内电解质水平等生

理因素以及外部环境因素干扰^[28], sEMG 信号通常包含大量复杂的观测噪声。因此, 传统解析的方法难以精确描述肌肉运动引起的 sEMG 与肢体姿态之间的转换关系。特别地, 肢体运动的随机性又增加了人体运动的建模难度。以人体上肢运动为例

$$x_k = f(x_{k-1}) + w_k \quad (1)$$

其中, $x_k \in \mathbf{R}^n$ 表示 k 时刻 n 维上肢关节状态向量, w_k 表示 k 时刻系统噪声, $f(\cdot)$ 表示系统状态转移函数。上肢运动状态的初始估计满足

$$\begin{cases} \hat{x}_{0|0} = E(x_0) \\ P_{0|0} = E\left((x_0 - \hat{x}_{0|0})(x_0 - \hat{x}_{0|0})^T\right) \end{cases} \quad (2)$$

其中, $\hat{x}_{0|0}$ 和 $P_{0|0}$ 表示初始状态估计及其方差。考虑到 sEMG 与上肢关节角度之间的复杂映射关系, 设计 LSTM 模块直接从 sEMG 中学习系统的非线性量测函数, $z_k \in \mathbf{R}^m$ 表示 m 维的 sEMG 量测向量, v_k 表示 k 时刻的量测噪声, 系统的量测模型表示如下

$$z_k = \text{LSTM}_h(x_k) + v_k \quad (3)$$

其中, LSTM_h 表示用于学习量测函数的 LSTM 模型, 过程噪声 w_k 和量测噪声 v_k 分别是均值为零、协方差为 Q_k 和 R_k 的互不相关的高斯白噪声

$$w_k \sim N(\mathbf{0}, Q_k) \quad (4)$$

$$v_k \sim N(\mathbf{0}, R_k) \quad (5)$$

其中, Q_k 和 R_k 分别表示 k 时刻过程噪声 w_k 和量测噪声 v_k 的协方差。针对肢体运动的随机性和 sEMG 量测噪声的复杂性, 利用 LSTM 模块从系统状态和 sEMG 测量中学习当前时刻的 Q_k 和 R_k

$$Q_k = \text{LSTM}_Q(x_{k-1}, c_{k-1}^Q) \quad (6)$$

$$R_k = \text{LSTM}_R(z_k, c_{k-1}^R) \quad (7)$$

其中, LSTM_Q 和 LSTM_R 表示用于学习过程噪声和量测噪声统计特性的 LSTM 模块, c_{k-1}^Q 和 c_{k-1}^R 是上一刻 LSTM_Q 和 LSTM_R 输出的隐藏单元, 由其对应的 LSTM 模块得到^[22]

$$f_k = \sigma(W_{fh}h_{k-1} + W_{fx}x_k + b_f) \quad (8)$$

$$i_k = \sigma(W_{ih}h_{k-1} + W_{ix}x_k + b_i) \quad (9)$$

$$o_k = \sigma(W_{oh}h_{k-1} + W_{ox}x_k + b_o) \quad (10)$$

$$\tilde{c}_k = \tanh(W_{ch}h_{k-1} + W_{cx}x_k + b_c) \quad (11)$$

$$c_k = f_k c_{k-1} + i_k \tilde{c}_k \quad (12)$$

$$h_k = o_k \tanh(c_k) \quad (13)$$

其中, $\sigma(\cdot)$ 表示 Sigmoid 函数, x_k 表示 k 时刻输入,

h_{k-1} 表示上一时刻 LSTM 隐藏单元输出, 通过计算遗忘门 f_k , 输入门 i_k , 输出门 o_k 以及记忆单元 c_k , 最终输出隐藏状态 h_k 。 $W_\#$ 表示门控单元权重, $b_\#$ 表示门控单元偏置。

所设计的 PUKF-net 内部结构如图 1 所示。该模型将基于 sEMG 的肢体运动估计任务拆分成三个 LSTM 模块。其中, LSTM_Q 和 LSTM_R 分别用于从 sEMG 数据中学习噪声协方差矩阵 Q_k 和 R_k , LSTM_h 模块用于学习人体运动状态与 sEMG 之间的映射关系。特别地, 在量测更新过程中采用渐进量测更新方式来提高系统估计的稳定性。最后, 在损失函数中增加了偏差项以提高 PUKF-net 训练效率。

2 运动估计方法

2.1 时间更新

根据 k 时刻输入的 sEMG, 通过 PUKF-net 估计当前人体上肢运动状态 x_k 。首先, 根据上一时刻运动状态 x_{k-1} 和当前时刻的量测 z_k 学习噪声统计特性 Q_k 和 R_k 。 LSTM_Q 和 LSTM_R 内部结构如图 2 所示。对 LSTM_Q 和 LSTM_R 模块的输出取幂使得 Q_k 和 R_k 为正定矩阵。 k 时刻 n 维状态 x_k 的均值和协方差用 $2n+1$ 个传播点近似表示

$$\begin{cases} \chi_{k-1|k-1}^i = \hat{x}_{k-1|k-1}, i = 0 \\ \chi_{k-1|k-1}^i = \hat{x}_{k-1|k-1} + \left(\sqrt{(n+\kappa)P_{k-1|k-1}}\right)_i, \\ \quad i = 1, 2, \dots, n \\ \chi_{k-1|k-1}^i = \hat{x}_{k-1|k-1} - \left(\sqrt{(n+\kappa)P_{k-1|k-1}}\right)_i, \\ \quad i = n+1, \dots, 2n \end{cases} \quad (14)$$

其中, $\hat{x}_{k-1|k-1}$ 和 $P_{k-1|k-1}$ 是系统 $k-1$ 时刻的状态估计及其协方差, n 表示系统状态 x 的维度, κ 是系

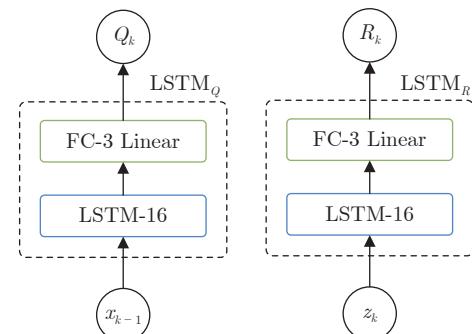


图 2 LSTM_Q , LSTM_R 网络结构

Fig. 2 Network structure of LSTM_Q and LSTM_R

统状态 x 的 Sigma 传播点间距比例因子。通过调节比例因子 κ 的取值大小，决定 Sigma 传播点之间的距离和其比重的大小，从而调整采样点所描述非线性状态函数后验分布的统计特性。在满足高斯分布假设的条件下，为使得 UKF 对称采样获取的后验分布效果最好， $n + \kappa = 3$ 被选择^[29]。根据系统状态模型，由采样点集 $\{\chi_{k-1|k-1}^i\}$, $i = 0, 1, \dots, 2n$ 可得状态预测的传播点

$$X_{k|k-1}^i = f(\chi_{k-1|k-1}^i), i = 0, 1, \dots, 2n \quad (15)$$

预测状态及其协方差表示如下

$$\hat{x}_{k|k-1} = \sum_{i=0}^{2n} W_i^m X_{k|k-1}^i \quad (16)$$

$$P_{k|k-1} = \sum_{i=0}^{2n} W_i^c (X_{k|k-1}^i - \hat{x}_{k|k-1}) \times (X_{k|k-1}^i - \hat{x}_{k|k-1})^T + Q_k \quad (17)$$

其中， Q_k 是由 $LSTM_Q$ 模块得到的系统噪声协方差，均值权重 W_i^m 和方差权重 W_i^c 取值如下

$$W_i^m = W_i^c = \begin{cases} \frac{\kappa}{n + \kappa}, & i = 0 \\ \frac{1}{2(n + \kappa)}, & i = 1, 2, \dots, 2n \end{cases} \quad (18)$$

2.2 渐进量测更新方法

由于人体肢体运动与 sEMG 之间的非线性映射关系复杂，且肢体运动估计器的稳定性不足，将采用渐进量测更新方法^[30-31]来修正人体肢体的运动估计。根据非线性卡尔曼滤波稳定性分析，不难发现人为增大测量噪声的协方差有助于提高估计器的稳定性^[30]。将量测更新分解成 N 步，同时每次渐进量测更新时测量噪声协方差被人为放大 $1/\Delta_j$ 倍， Δ_j 表示第 j 步的迭代步长^[31-32]。令渐进更新的伪时间点为 $\lambda_j \in [0, 1]$, $j = 0, 1, \dots, N$ ，第 j 步的伪时间点 $\lambda_j = \lambda_{j-1} + \Delta_j$ ，且满足 $\lambda_0 = 0$ 和 $\lambda_N = 1$ 。根据状态预测中得到的 $\hat{x}_{k|k-1}$ 和 $P_{k|k-1}$ ，令 $\hat{x}_{k|k, \lambda_0} = \hat{x}_{k|k-1}$, $P_{k|k, \lambda_0} = P_{k|k-1}$ ，可得伪时间 λ_j ，传播点集 $\{\chi_{k|k, \lambda_{j-1}}^i\}$, $i = 1, 2, \dots, 2n$ 经过量测模型 $LSTM_h$ 传递可得量测预测的传播点及其均值

$$Z_{k|k, \lambda_j}^i = LSTM_h(\chi_{k|k, \lambda_{j-1}}^i) \quad (19)$$

$$\hat{z}_{k|k, \lambda_j} = \sum_{i=0}^{2n} W_i^m Z_{k|k, \lambda_j}^i \quad (20)$$

其中，预测状态估计的传播点表示如下

$$\begin{cases} \chi_{k|k, \lambda_{j-1}}^i = \hat{x}_{k|k, \lambda_{j-1}}, i = 0 \\ \chi_{k|k, \lambda_{j-1}}^i = \hat{x}_{k|k, \lambda_{j-1}} + (\sqrt{(n + \kappa)P_{k|k, \lambda_{j-1}}})_i, \\ i = 1, 2, \dots, n \\ \chi_{k|k, \lambda_{j-1}}^i = \hat{x}_{k|k, \lambda_{j-1}} - (\sqrt{(n + \kappa)P_{k|k, \lambda_{j-1}}})_i, \\ i = n + 1, \dots, 2n \end{cases} \quad (21)$$

其中， $\hat{x}_{k|k, \lambda_{j-1}}$ 和 $P_{k|k, \lambda_{j-1}}$ 表示系统 k 时刻下，伪时间步 $j-1$ 的状态估计及其协方差，量测函数由 $LSTM_h$ 模块学习得到，其内部结构及计算过程如图 3 所示，其中， $\lambda = \sqrt{\kappa + n}$ ，系统状态协方差及其状态与量测的互协方差如下

$$P_{zz, k|k, \lambda_j} = \sum_{i=0}^{2n} W_i^c (Z_{k|k, \lambda_j}^i - \hat{z}_{k|k, \lambda_j}) \times (Z_{k|k, \lambda_j}^i - \hat{z}_{k|k, \lambda_j})^T + \frac{R_k}{\Delta_j} \quad (22)$$

$$P_{xz, k|k, \lambda_j} = \sum_{i=0}^{2n} W_i^c (\chi_{k|k, \lambda_{j-1}}^i - \hat{x}_{k|k, \lambda_{j-1}}) \times (Z_{k|k, \lambda_j}^i - \hat{z}_{k|k, \lambda_j})^T \quad (23)$$

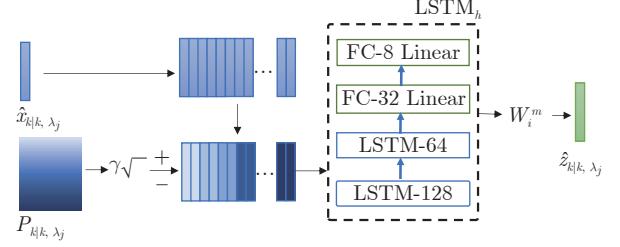


Fig.3 Calculation process including $LSTM_h$

滤波增益 K 以及当前伪时间点下的状态估计和估计方差如下

$$K_{k|k, \lambda_j} = P_{xz, k|k, \lambda_j} (P_{zz, k|k, \lambda_j})^{-1} \quad (24)$$

$$\begin{cases} \hat{x}_{k|k, \lambda_j} = \hat{x}_{k|k, \lambda_{j-1}} + K_{k|k, \lambda_j} (z_k - \hat{z}_{k|k, \lambda_j}) \\ P_{k|k, \lambda_j} = P_{k|k, \lambda_{j-1}} - K_{k|k, \lambda_j} P_{zz, k|k, \lambda_j} K_{k|k, \lambda_j}^T \end{cases} \quad (25)$$

在第 N 次更新后 $\lambda_N = 1$ ，最终得到当前时刻目标后验状态向量 $\hat{x}_{k|k}$ 和协方差 $P_{k|k}$ 。由此，完成 PUKF-net 的预测和渐进量测更新。最后，PUKF-net 算法流程如算法 1 所示。用于描述量测模型的 $LSTM_h$ 网络具有较强非线性，线性化误差对滤波器稳定性的影响较大。根据 UKF、PUKF 等稳定性分析

不难发现, 渐进量测更新过程将有助于降低滤波器稳定性的破坏风险, 同时减少了滤波过程中的线性化误差。本文利用渐进高斯滤波方法的优势, 引入先验到后验的渐变过程, “放大”量测噪声协方差来渐进地包含传感器量测, 从而提升了滤波的稳定性。

算法 1. PUKF-net 算法

- 1) 初始化
- 2) **while** do
- 3) 时间更新: 式 (15) ~ (17)
- 4) **for** $i = 1 : N$ **do**
- 5) 量测更新: 式 (19) ~ (25)
- 6) **end for**
- 7) **end while**

2.3 损失函数

计算真值 x_k 与预测值 $\hat{x}_{k|k, \lambda_j}$ 的偏差作为 $LSTM_h$ 和 $LSTM_R$ 的模型损失, 增加了偏差项以确保 $LSTM_Q$ 的梯度流通过反向传播被增强^[22], 关节角度 θ 的损失函数 $L(\theta)$ 表示如下

$$L(\theta) = \frac{1}{T} \sum_{k=1}^T \left(\|x_k - \hat{x}_{k|k-1}\|^2 + \|x_k - \hat{x}_{k|k}\|^2 \right) \quad (26)$$

其中, T 表示单个训练样本的时间步长, x_k 为系统真值, $\hat{x}_{k|k-1}$ 和 $\hat{x}_{k|k}$ 分别为肢体状态预测值和更新值。

3 实验分析

以人体上肢肘关节运动为例, 设计实验采集肢体 sEMG 以及关节角度真值, 通过所提出的 PUKF-net 实现基于 sEMG 的肢体运动估计, 并与其他方法进行比较, 证明该模型的有效性。

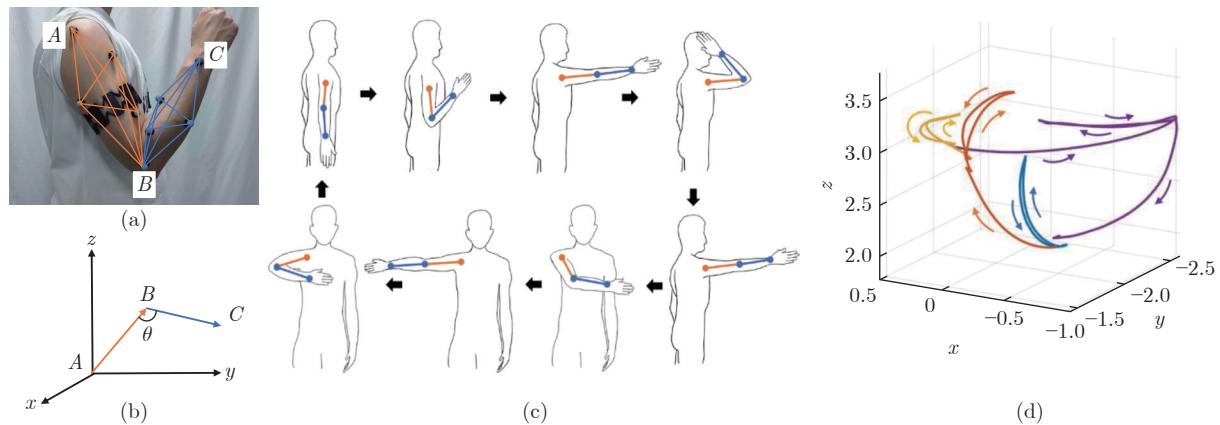


图 4 实验设计 ((a) 传感器布局; (b) 关节角度坐标; (c) 轨迹规划; (d) Optitrack 采集到手腕关节点轨迹)

Fig.4 Experiment design ((a) Sensor layout; (b) Joint angle coordinates; (c) Trajectory planning; (d) Track of wrist joint collected by Optitrack)

3.1 数据采集

为验证 PUKF-net 的有效性, 搭建了一套 sEMG 和肘关节角度采集系统。使用 Myo 手环采集上肢在肘关节运动中的 sEMG, Myo 手环采样频率为 200 Hz, 能够同时采集 8 通道数据。如图 4(a) 所示, Myo 佩戴在受试者右侧大臂用于采集运动过程的 sEMG。在肘关节角度采集部分, 采用 Optitrack 视觉捕捉系统分析上肢关节运动特性。Optitrack 系统通过 12 台 200 Hz 高速相机捕捉发光标记点位置, 并根据预先标定的相机坐标和世界坐标输出标记点在世界坐标系内的三维坐标。在大臂和小臂上分别放置多个标记点, 防止运动过程中单个标记点丢失。如图 4(b) 所示, 将大臂小臂的方向向量映射在三维坐标系中, AB 表示受试者大臂, BC 表示受试者小臂, 夹角 θ 即为上肢肘关节角度。

12 名肢体健康的测试者参与实验, 测试者的身体参数如表 1 所示。实验时测试者站在 Optitrack 工作空间, 按照图 4(c) 规划轨迹依次完成 4 组肘关节屈伸动作。肘关节屈伸动作需要肘关节屈曲至最大角度, 停顿后缓慢伸展。每个位置进行 10 组肘关节的屈曲和伸展。测试者充分休息后再次进行 10 组运动。为了防止肌肉疲劳, 每组实验之间有 3 min 的休息时间, 实验持续约 30 min。图 4(d) 展示了实验过程中 Optitrack 捕捉到的手腕标记点在三维空间中的轨迹。

3.2 实验结果

人体上肢肘关节屈伸运动分为肘关节屈曲和肘关节伸展两个过程, 根据解剖学知识, 肘关节屈曲运动主要由肱二头肌、肱肌和肱桡肌协同完成, 肘关节伸展运动则主要与肱三头肌的肌肉活动相关。

表 1 测试者身体参数
Table 1 Physiological information of subjects

测试者	年龄	身高 (cm)	体重 (kg)	性别
S1	31	155	65	女
S2	24	161	53	女
S3	29	182	85	男
S4	20	177	61	男
S5	25	173	75	男
S6	28	175	65	男
S7	30	160	47	女
S8	25	171	72	男
S9	22	175	70	男
S10	24	162	50	女
S11	32	159	54	女
S12	29	170	78	男

测试者均按照图 5(a)、图 5(b) 方式佩戴 Myo 手环, 然而实际采集到的信号(如图 5(d))表明, 肘关节伸展过程中肱三头肌部分 sEMG 变化并不明显。为了排除冗余信号的干扰, 利用非负矩阵分解方法^[33]得到协同矩阵 W (图 5(c)), 矩阵中数值越大则表示该通道信号协同性越强, 选取协同性较强的 4 个通道, 即通道 4~7 作为 sEMG 有效信号。

在获取 sEMG 有效信号后, 采用均方根欠采样方法^[34]对有效 sEMG 通道进行预处理, 然后将预处理后的信号输入 PUKF-net 进行训练。本文建立了 LSTM、LSTM-KF^[22]、以及本文所设计的 PUKF-net 模型, 并在 PyTorch 框架中实现了所有网络的

训练和测试。在初始化阶段, 对于所有网络的 LSTM 以及 LSTM-cell 单元采用 Xavier 初始化。初始学习率设为 0.001, 通过 ADAM 优化器在统一批量中进行 200 次迭代训练。特别地, 由于 LSTM 隐藏层数量和节点个数会直接影响网络性能, 因此用于对比的 LSTM 和 LSTM-KF 采用与 PUKF-net 相同的隐藏层。随机选取所有样本中的 50% 作为训练集, 其余数据作为测试集。

以测试者 S1~S4 的数据为例, 三种模型基于 sEMG 估计的人体肘关节角度曲线如图 6 所示, 可以看出, 通过 PUKF-net 估计的肘关节角度比其他两个模型的估计值更接近真实值。特别地, LSTM 模型的估计值波动较明显, 在不同测试者数据集上表现差异较大, 这是由于测试者的 sEMG 存在较大的个体差异。得益于卡尔曼滤波的抗噪性, LSTM-KF 和 PUKF-net 的预测值波动平缓, PUKF-net 整体上更接近真实值。

通过相关系数 R^2 和 RMSE 评估各个模型性能。 R^2 表示估计结果与真实值的相关性, RMSE 计算真实值与估计值之间的幅值差异。三种模型均能得到有效的人体肘关节角度估计, 且测试者身体参数差异与估计结果没有明显关联, 表 2 列出了 LSTM、LSTM-KF 和 PUKF-net 在 12 名测试者测试数据集上的相关系数和均方根误差。LSTM、LSTM-KF 和 PUKF-net 的平均 RMSE 分别为 20.422 ± 3.442 , 16.069 ± 2.640 , 13.668 ± 1.793 , PUKF-net 能够在相同隐藏层条件下取得最小的 RMSE。平均 R^2 为 0.709 ± 0.057 , 0.823 ± 0.041 , 0.865 ± 0.024 , 相比于 LSTM 和 LSTM-KF, PUKF-net 通过 UT 变换和渐进量测方法使得模型估计精度更高, 模型稳定。

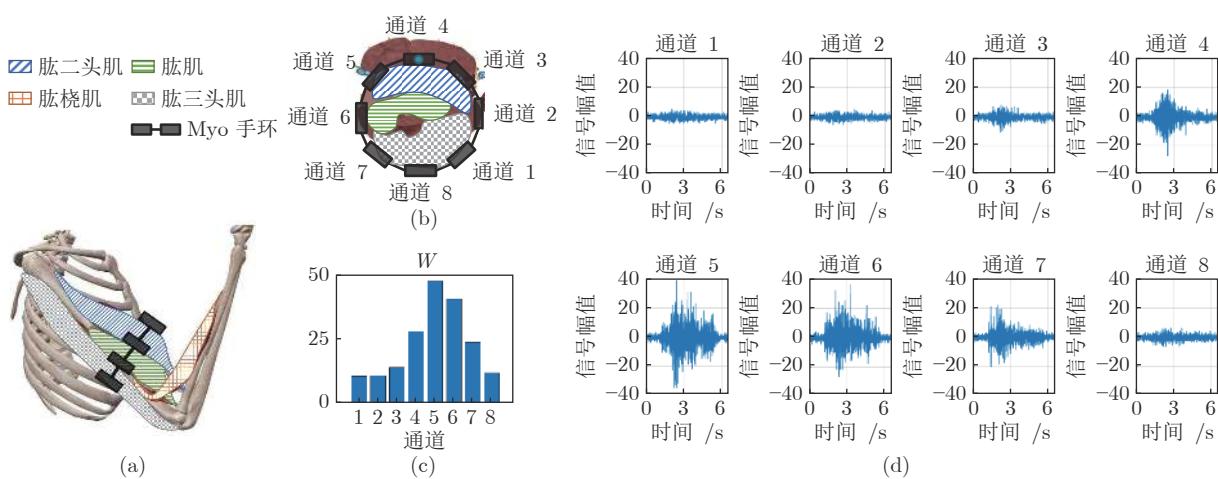


图 5 sEMG 分析 ((a) 人体大臂肌肉分布; (b) Myo 位置肌肉横截面; (c) 协同矩阵 W ; (d) sEMG 原始信号)

Fig.5 sEMG analysis ((a) Muscle distribution of human upper arm; (b) Cross-section of Myo wearing position; (c) Non-negative matrix factorization comatrix W ; (d) Original signal of sEMG)

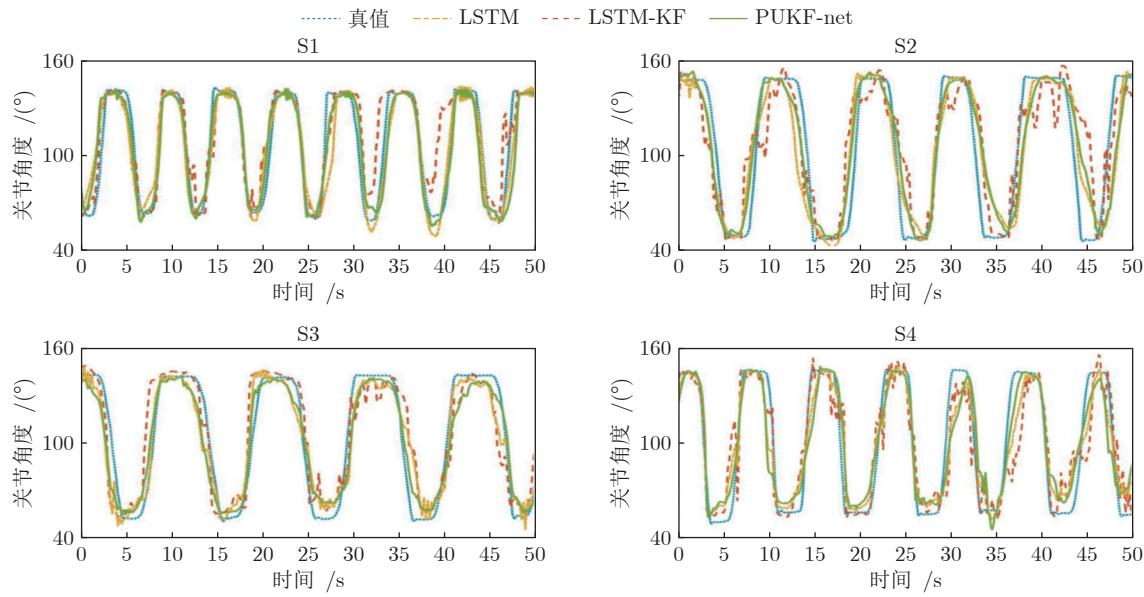


图 6 关节角度估计曲线
Fig. 6 Joint angle estimation curve

表 2 LSTM、LSTM-KF、PUKF-net 在测试集上的 RMSE 和 R^2
Table 2 RMSE and R^2 of LSTM, LSTM-KF, PUKF-net

测试者	RMSE			R^2		
	LSTM	LSTM-KF	PUKF-net	LSTM	LSTM-KF	PUKF-net
S1	15.913	12.668	11.940	0.823	0.896	0.906
S2	24.568	18.677	15.473	0.622	0.748	0.829
S3	19.736	16.996	14.044	0.737	0.825	0.872
S4	20.653	13.315	12.668	0.679	0.863	0.876
S5	26.746	20.675	16.448	0.629	0.761	0.824
S6	16.793	13.664	11.588	0.803	0.880	0.905
S7	22.193	17.164	14.187	0.699	0.852	0.868
S8	17.984	15.241	12.294	0.748	0.827	0.880
S9	22.537	18.464	15.624	0.710	0.817	0.861
S10	24.142	18.555	16.165	0.655	0.809	0.848
S11	14.601	11.271	10.545	0.682	0.792	0.844
S12	19.196	16.137	13.044	0.721	0.804	0.865
平均值	20.422	16.069	13.668	0.709	0.823	0.865

性也有所提高，在关节角度估计中的 RMSE 下降了 14.9%， R^2 提高了 5.1%，验证了本文提出的 PUKF-net 模型的有效性。

4 结论

通过结合 LSTM 与 UKF 的优势，本文设计了 PUKF-net 模型实现了基于 sEMG 的上肢运动估计。PUKF-net 利用数据驱动的思想解决肢体运动

估计中的建模难问题。同时，采用渐进量测更新方法来解决运动状态估计过程中线性化误差引起的不稳定问题。实验表明，所提出的 PUKF-net 模型在基于 sEMG 的上肢关节角度估计中的效果优于 LSTM 和 LSTM-KF 模型。在未来的工作中，将使用所提出的 PUKF-net 实现基于多源异构传感器融合的运动估计。通过整合多源传感器的物理信息和生理信息，提高机器人柔性能感知能力和估计精度。

References

- 1 Ding Q C, Han J D, Zhao X G. Continuous estimation of human multi-joint angles from sEMG using a state-space model. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, **25**(9): 1518–1528
- 2 Ding Qi-Chuan, Xiong An-Bin, Zhao Xin-Gang, Han Jian-Da. A review on researches and applications of sEMG-based motion intent recognition methods. *Acta Automatica Sinica*, 2016, **42**(1): 13–25
(丁其川, 熊安斌, 赵新刚, 韩建达. 基于表面肌电的运动意图识别方法研究及应用综述. 自动化学报, 2016, **42**(1): 13–25)
- 3 Liu H, Tao J, Lyu P, Tian F. Human-robot cooperative control based on sEMG for the upper limb exoskeleton robot. *Robotics and Autonomous Systems*, 2020, **125**: Article No. 103350
- 4 Chen Ling-Ling, Li Shan-Shan, Liu Zuo-Jun, Zhang Yan. Construction of lower limb's functional muscle network and its application based on surface EMG. *Acta Automatica Sinica*, 2017, **43**(3): 407–417
(陈玲玲, 李珊珊, 刘作军, 张燕. 基于表面肌电的下肢肌肉功能网络构建及其应用研究. 自动化学报, 2017, **43**(3): 407–417)
- 5 Pallotti A, Orenco G, Saggio G. Measurements comparison of finger joint angles in hand postures between an sEMG armband and a sensory glove. *Biocybernetics and Biomedical Engineering*, 2021, **41**(2): 605–616
- 6 Ao D, Song R, Gao J W. Movement performance of human—Robot cooperation control based on EMG-driven hill-type and proportional models for an ankle power-assist exoskeleton robot. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, **25**(8): 1125–1134
- 7 He Y, Li F, Li J K, Liu J S, Wu X Y. An sEMG based adaptive method for human-exoskeleton collaboration in variable walking environments. *Biomedical Signal Processing and Control*, 2022, **74**: Article No. 103477
- 8 Zhang Jun-Hao, He Bai-Yue, Yang Xu-Sheng, Zhang Wen-An. A review on wearable inertial sensor based human motion tracking. *Acta Automatica Sinica*, 2019, **45**(8): 1439–1454
(张鋆豪, 何百岳, 杨旭升, 张文安. 基于可穿戴式惯性传感器的人体运动跟踪方法综述. 自动化学报, 2019, **45**(8): 1439–1454)
- 9 Bahador A, Yousefi M, Marashi M, Bahador O. High accurate lightweight deep learning method for gesture recognition based on surface electromyography. *Computer Methods and Programs in Biomedicine*, 2020, **195**: Article No. 105643
- 10 Wang C, Guo W Y, Zhang H, Guo L L, Huang C C, Lin C. sEMG-based continuous estimation of grasp movements by long-short term memory network. *Biomedical Signal Processing and Control*, 2020, **59**: Article No. 101774
- 11 Zhu Yu, Zhao Jiang-Kun, Wang Yi-Ning, Zheng Bing-Bing. A review of human action recognition based on deep learning. *Acta Automatica Sinica*, 2016, **42**(6): 848–857
(朱煜, 赵江坤, 王逸宁, 郑兵兵. 基于深度学习的人体行为识别算法综述. 自动化学报, 2016, **42**(6): 848–857)
- 12 Yang W, Yang D P, Liu Y, Liu H. Decoding simultaneous multi-DOF wrist movements from raw EMG signals using a convolutional neural network. *IEEE Transactions on Human-Machine Systems*, 2019, **49**(5): 411–420
- 13 Liu J, Ren Y P, Xu D L, Kang S H, Zhang L Q. EMG-based real-time linear-nonlinear cascade regression decoding of shoulder, elbow, and wrist movements in able-bodied persons and stroke survivors. *IEEE Transactions on Biomedical Engineering*, 2020, **67**(5): 1272–1281
- 14 Xu L F, Chen X, Cao S, Zhang X, Chen X. Feasibility study of advanced neural networks applied to sEMG-based force estimation. *Sensors*, 2018, **18**(10): Article No. 3226
- 15 Lu Y Z, Wang H, Zhou B, Wei C F, Xu S Q. Continuous and simultaneous estimation of lower limb multi-joint angles from sEMG signals based on stacked convolutional and LSTM models. *Expert Systems With Applications*, 2022, **203**: Article No. 117340
- 16 Chai Y Y, Liu K P, Li C X, Sun Z B, Jin L, Shi T. A novel method based on long short-term memory network and discrete-time zeroing neural algorithm for upper-limb continuous estimation using sEMG signals. *Biomedical Signal Processing and Control*, 2021, **67**: Article No. 102416
- 17 Chen C H, Lu C X, Wang B, Trigoni N, Markham A. DynaNet: Neural Kalman dynamical model for motion estimation and prediction. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, **32**(12): 5479–5491
- 18 Zhang J, Wu Y N, Jiao S. Research on trajectory tracking algorithm based on LSTM-UKF. In: Proceedings of the 7th IEEE International Conference on Network Intelligence and Digital Content (IC-NIDC). Beijing, China: IEEE, 2021. 61–65
- 19 Jondhale S R, Deshpande R S. Kalman filtering framework-based real time target tracking in wireless sensor networks using generalized regression neural networks. *IEEE Sensors Journal*, 2019, **19**(1): 224–233
- 20 Lim H, Ryu H, Rhudy M B, Lee D, Jang D, Lee C, et al. Deep learning-aided synthetic airspeed estimation of UAVs for analytical redundancy with a temporal convolutional network. *IEEE Robotics and Automation Letters*, 2021, **7**(1): 17–24
- 21 Li J M, Chen C W, Cheng T H. Motion prediction and robust tracking of a dynamic and temporarily-occluded target by an unmanned aerial vehicle. *IEEE Transactions on Control Systems Technology*, 2020, **29**(4): 1623–1635
- 22 Coskun H, Achilles F, DiPietro R, Navab N, Tombari F. Long short-term memory Kalman filters: Recurrent neural estimators for pose regularization. In: Proceedings of the IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017. 5524–5532
- 23 Bao T Z, Zhao Y H, Zaidi S A R, Xie S Q, Yang P F, Zhang Z Q. A deep Kalman filter network for hand kinematics estimation using sEMG. *Pattern Recognition Letters*, 2021, **143**: 88–94
- 24 Zhao C, Sun L, Yan Z, Neumann G, Duckett T, Stolk R. Learning Kalman network: A deep monocular visual odometry for on-road driving. *Robotics and Autonomous Systems*, 2019, **121**: Article No. 103234
- 25 Revach G, Shlezinger N, van Sloun R J G, Eldar Y C. Kalmanet: Data-driven Kalman filtering. In: Proceedings of the ICASSP 2021 — 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Toronto, ON, Canada: IEEE, 2021. 3905–3909
- 26 Yang X S, Zhang W A, Liu A D, Yu L. Linear fusion estimation for range-only target tracking with nonlinear transformation. *IEEE Transactions on Industrial Informatics*, 2020, **16**(10): 6403–6412
- 27 Zhang Wen-An, Chen Guo-Qing, Yang Xu-Sheng. Mobile robot localization method in UHF-RFID. *Control and Decision*, 2018, **33**(10): 1807–1812
(张文安, 陈国庆, 杨旭升. UHF-RFID 环境下的移动机器人定位方法. 控制与决策, 2018, **33**(10): 1807–1812)
- 28 Li Zi-You, Zhao Xin-Gang, Zhang Bi, Ding Qi-Chuan, Zhang Dao-Hui, Han Jian-Da. Review of sEMG-based motion intent recognition methods in non-ideal conditions. *Acta Automatica Sinica*, 2021, **47**(5): 955–969
(李自由, 赵新刚, 张弼, 丁其川, 张道辉, 韩建达. 基于表面肌电的意图识别方法在非理想条件下的研究进展. 自动化学报, 2021, **47**(5): 955–969)
- 29 Julier S, Uhlmann J, Durrant-Whyte H F. A new method for the nonlinear transformation of means and covariances in filters and estimators. *IEEE Transactions on Automatic Control*, 2000, **45**(3): 477–482
- 30 Yang X S, Zhang W A, Yu L, Shi L. Performance evaluation of

- distributed linear regression Kalman filtering fusion. *IEEE Transactions on Automatic Control*, 2021, **66**(6): 2889–2896
- 31 Zheng Ting-Ting, Yang Xu-Sheng, Zhang Wen-An, Yu Li. A target tracking method in Gaussian progressive filtering framework. *Acta Automatica Sinica*, 2018, **44**(12): 2250–2258
(郑婷婷, 杨旭升, 张文安, 俞立. 一种高斯渐进滤波框架下的目标跟踪方法. 自动化学报, 2018, **44**(12): 2250–2258)
- 32 Yang X S, Zhao C, Chen B. Progressive Gaussian approximation filter with adaptive measurement update. *Measurement*, 2019, **148**: Article No. 106898
- 33 Xie Ping, Li Xin-Xin, Yang Chun-Hua, Yang Fang-Mei, Chen Xiao-Ling, Wu Xiao-Guang. Research on the intermuscular synergy and coupling analysis based on surface EMG nonnegative matrix factorization-coherence. *Chinese Journal of Biomedical Engineering*, 2017, **36**(2): 150–157
(谢平, 李欣欣, 杨春华, 杨芳梅, 陈晓玲, 吴晓光. 基于表面肌电非负矩阵分解与一致性的肌间协同耦合关系研究. 中国生物医学工程学报, 2017, **36**(2): 150–157)
- 34 Tong Li-Na, Hou Zeng-Guang, Peng Liang, Wang Wei-Qun, Chen Yi-Xiong, Tan Min. Multi-channel sEMG time series analysis based human motion recognition method. *Acta Automatica Sinica*, 2014, **40**(5): 810–821
(佟丽娜, 侯增广, 彭亮, 王卫群, 陈翼雄, 谭民. 基于多路sEMG时序分析的人体运动模式识别方法. 自动化学报, 2014, **40**(5): 810–821)



杨旭升 浙江工业大学信息工程学院副研究员. 主要研究方向为信息融合估计, 人体运动估计和目标定位.
E-mail: xsyang@zjut.edu.cn
(YANG Xu-Sheng) Associate researcher at the College of Information Engineering, Zhejiang University of Technology. His research interest covers information fusion estimation, human motion estimation, and target positioning.)



王雪儿 浙江工业大学信息工程学院硕士研究生. 主要研究方向为人体运动估计, 信息融合估计.

E-mail: wangxueer@zjut.edu.cn

(WANG Xue-Er) Master student at the College of Information Engineering, Zhejiang University of Technology. Her research interest covers human motion estimation and information fusion estimation.)



汪鹏君 温州大学电气与电子工程学院教授. 主要研究方向为人工智能, 信息安全.

E-mail: wangpengjun@wzu.edu.cn

(WANG Peng-Jun) Professor at the College of Electrical and Electronic Engineering, Wenzhou University. His research interest covers artificial intelligence and information security.)



张文安 浙江工业大学信息工程学院教授. 主要研究方向为多源信息融合估计及应用. 本文通信作者.

E-mail: wazhang@zjut.edu.cn

(ZHANG Wen-An) Professor at the College of Information Engineering, Zhejiang University of Technology.

His research interest covers multi-sensor information fusion estimation and its applications. Corresponding author of this paper.)