

基于门控渐进高斯滤波网络的人体运动估计

杨旭升^{1,2} 杨基业^{1,2} 张文安^{1,2}

摘要 针对表面肌电信号和人体运动等模型误差引起的运动估计性能下降问题, 提出一种基于门控渐进高斯滤波网络 (GPGF-net) 的人体运动估计方法, 以实现模型误差的补偿以及提升运动估计的精度. 首先, 设计门控记忆机制来调控信息流, 以学习出系统状态的长期依赖与观测信号的时变特性, 从而动态调整误差补偿项的分布参数. 其次, 通过融合贝叶斯滤波与深度学习的优势, 引入渐进式观测更新策略到 GPGF-net, 以减小非线性近似误差以及增强模型鲁棒性. 最后, 通过人体肢体运动估计实验表明, 相较于现有方法, GPGF-net 显著提高了估计精度, 均方根误差降低 15.62%, 相关系数 R^2 提升 5.08%, 验证了所提方法的有效性.

关键词 高斯滤波网络; 模型误差补偿; 人体运动估计; 表面肌电信号

引用格式 杨旭升, 杨基业, 张文安. 基于门控渐进高斯滤波网络的人体运动估计. 自动化学报, 2026, 52(8): 1769–1780

DOI 10.16383/j.aas.c250250

CSTR 32138.14.j.aas.c250250

Gated Progressive Gaussian Filtering Network for Human Motion Estimation

YANG Xu-Sheng^{1,2} YANG Ji-Ye^{1,2} ZHANG Wen-An^{1,2}

Abstract To address the issue of degraded motion estimation performance caused by surface electromyography model and human motion model errors, this paper proposes a human motion estimation method based on gated progressive Gaussian filtering network (GPGF-net), aiming to effectively compensate for model errors and improve the accuracy of motion estimation. First, a gated memory mechanism is designed to regulate the flow of information, enabling the model to learn long-term dependencies in system states and time-varying characteristics of observation signals, thereby dynamically adjusting the distribution parameters of the error compensation term. Secondly, by integrating the advantages of Bayesian filtering and deep learning, a progressive multi-step observation update strategy is introduced into the GPGF-net to reduce nonlinear approximation errors and enhance model robustness. Finally, experiments on human limb motion estimation demonstrate that, compared with existing methods, GPGF-net significantly improves estimation accuracy, reducing the root mean square error by 15.62% and increasing the correlation coefficient R^2 by 5.08%, thus validating the effectiveness of the proposed method.

Keywords Gaussian filtering network; model error compensation; human motion estimation; surface electromyography

Citation Yang Xu-Sheng, Yang Ji-Ye, Zhang Wen-An. Gated progressive Gaussian filtering network for human motion estimation. *Acta Automatica Sinica*, 2026, 52(8): 1769–1780

在人机交互、康复机器人和假肢控制等领域, 基于表面肌电信号 (surface electromyography, sEMG) 的人体运动估计技术因其能捕捉超前的神经控制信息而展现出独特优势^[1–2]. sEMG 作为一种无创生物电信号, 能反映肌肉激活状态与运动意图

以及为肢体运动提供预测能力. 然而, 由于 sEMG 具有强非线性、时变性和易受干扰等特点, 同时受人体运动复杂性影响, 给传统解析建模方法带来挑战^[3–4]. 通常受生理参数的个体差异、软组织形变以及观测噪声的非高斯性等因素影响, 使得理论模型与实际动态之间存在不可避免的误差, 进而影响运动估计的精度与鲁棒性. 因此, 如何有效补偿建模误差是提升 sEMG 运动估计性能的重要途径.

当前 sEMG 运动估计建模方法主要分为基于生物力学的机理模型与数据驱动的深度学习方法两大类^[5–6]. 机理模型通过生物力学方程将 sEMG 与肌力及运动进行关联, 物理可解释性强^[7]. 然而, 其主要问题在于: 其一, 该建模方法依赖的生理参数难以实时精确测量, 常因简化或离线标定而引入参数误差; 其二, 传统基于微分方程的建模方法难以

收稿日期 2025-06-09 录用日期 2025-12-31

Manuscript received June 9, 2025; accepted December 31, 2025
国家自然科学基金 (62473335, U25A20456, W2421117), 杭州市科技发展计划 (2022AIZD0080) 资助

Supported by National Natural Science Foundation of China (62473335, U25A20456, W2421117) and Science and Technology Development Program of Hangzhou (2022AIZD0080)

本文责任编辑 许斌

Recommended by Associate Editor XU Bin

1. 浙江工业大学信息工程学院 杭州 310023 2. 浙江省复杂系统智能感知与控制重点实验室 杭州 310023

1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023 2. Zhejiang Key Laboratory of Intelligent Perception and Control for Complex Systems, Hangzhou 310023

捕捉人体运动复杂的非马尔科夫特性与时变的肌肉协同模式. 这些问题制约了人体运动估计精度. 近年来, 深度学习被广泛应用^[8-11]. 时间卷积网络 (temporal convolutional network, TCN) 凭借其处理长序列和并行计算的优势成为流行的架构^[12-14]. 例如, Wang 等^[15]结合 TCN 与双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM) 来提升多关节角度和力矩估计的精度与稳健性; Du 等^[16]融合 TCN 和 LSTM 来连续估计手腕运动. 这类方法虽精度较高, 但其数据依赖特性使其在先验知识融合、大规模数据需求、可解释性及泛化能力方面存在局限性. 为融合两类方法的优势, 卡尔曼滤波 (Kalman filter, KF) 因具有噪声抑制和实时性优点被引入^[9]. 例如, Han 等^[17]结合扩展卡尔曼滤波 (extended Kalman filter, EKF) 和 Hill 模型 (Hill muscle model) 来构建状态空间模型, 以实现基于 sEMG 的肢体运动估计. 然而, KF 性能依赖于精确的系统模型及线性高斯噪声假设, 随着模型误差增加, 其效果不足逐渐明显^[18-19]. 为此, 结合深度学习与贝叶斯滤波的方式成为解决这一难题的重要方法, 即卡尔曼滤波网络 (Kalman filter network, KFN)^[20-21]. 例如, Coskun 等^[22]提出的 LSTM-KF (LSTM-based Kalman filter process) 利用 LSTM 模块来学习 KF 的状态、观测及噪声模型; Zhao 等^[23]设计的学习型卡尔曼网络 (learning Kalman network, LKN) 采用神经网络来建模系统方程和生成自适应卡尔曼增益; Liu 等^[24]通过 LSTM 来改善模型以及提升贝叶斯滤波性能. KFN 虽通过端到端学习提升了模型的适应能力, 但非线性网络的引入放大了其滤波更新中的线性化误差^[25-27], 制约着网络的性能. 尤其在系统存在未建模动态或突变扰动时, 模型误差的传播会削弱 KFN 的补偿能力. Yan 等^[28]提出一种基于门控贝叶斯循环网络 (explainable gated Bayesian recurrent neural network, EGBRNN) 的方法, 利用状态-记忆联合建模来补偿动态不确定性下的模型失配问题. 然而, 该方法采用的单一记忆变量难以将状态演化与观测过程中的误差来源进行解耦, 这将影响模型误差补偿的有效性.

针对上述问题, 本文提出一种门控渐进高斯滤波网络 (gated progressive Gaussian filtering network, GPGF-net) 来动态补偿模型误差, 以实现基于 sEMG 的人体运动状态估计. 首先, 引入门控记忆机制, 分别设计状态预测门和状态更新门以捕捉状态演化规律和观测噪声特性变化, 从而动态调整误差补偿项的分布参数; 其次, 利用渐进式状态修正策略, 将单步观测更新分解为多步融合过程, 减

小运动估计的线性化近似误差; 最后, 通过采集肢体运动中的关节角度与同步 sEMG, 验证 GPGF-net 的有效性与优越性.

1 问题描述

基于 sEMG 的人体运动估计主要难点在于: 由于 sEMG 的时变性、个体差异及易受干扰特性^[4], 以及复杂人体运动动力学的非线性与非马尔科夫性, 导致理论模型与实际过程存在模型误差. 该误差包括状态转移模型误差和观测模型误差, 将制约人体运动估计精度. 为此, 构建包含动态补偿项的状态空间系统. 设 $x_k \in \mathbf{R}^n$ 为 k 时刻 n 维人体关节状态向量, w_k 为系统噪声, 则状态转移方程可表示为

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

其中, $f(\cdot)$ 表示基于生物力学原理构建的状态转移函数; Δx_k 用于补偿因长期依赖关系、模型简化或参数不确定性等造成的未建模动态项. 不同于传统方法中仅依赖当前状态 x_{k-1} 的建模方式, 本文通过引入一个长度为 L 的历史状态序列窗口

$$\mathcal{X}_{k-1} = \{x_{k-1}, x_{k-2}, \dots, x_{k-L}\} \quad (2)$$

来显式建模状态演化过程中的时间依赖特性. 由此定义

$$\Delta x_k := f^\Delta(c_k^f), \quad c_k^f := \mathcal{M}_c(c_{k-1}^f, \mathcal{X}_{k-1}, F_k) \quad (3)$$

其中, $f^\Delta(\cdot)$ 为由预测门网络生成的非线性补偿函数; c_k^f 为预测记忆变量, 用于捕捉状态演化的长期依赖规律; $\mathcal{M}_c$ 表示递归更新机制, 结合先验模型雅可比矩阵 F_k (即状态转移函数在 x_{k-1} 处的局部梯度信息) 和历史状态序列 $\mathcal{X}_{k-1}$ 来动态调整记忆内容, 从而增强模型的鲁棒性. 人体运动状态的初始估计满足

$$\begin{cases} \hat{x}_{0|0} = E[x_0] \\ P_{0|0} = E[(x_0 - \hat{x}_{0|0})(x_0 - \hat{x}_{0|0})^T] \end{cases} \quad (4)$$

其中, $\hat{x}_{0|0}$ 和 $P_{0|0}$ 表示初始状态估计及其协方差. 针对观测模型误差问题, 构建包含误差补偿项的观测模型如下

$$z_k = h(x_k) + \Delta z_k + v_k \quad (5)$$

其中, $h(\cdot)$ 为非线性观测函数, 用于描述系统状态到观测空间的映射关系; $z_k \in \mathbf{R}^m$ 表示 m 维的 sEMG 观测向量; v_k 为观测噪声. 过程噪声 w_k 和观测噪声 v_k 分别服从均值为零、协方差为 Q_k 和 R_k 的互不相关的高斯白噪声分布. 为显式建模历史状态对观测的影响, 引入观测端的记忆机制

$$\Delta z_k := h^\Delta(c_k^h), \quad c_k^h := \mathcal{N}_c(c_{k-1}^h, z_k, H_k, i_k^{emg}) \quad (6)$$

其中, $h^\Delta(\cdot)$ 为由状态更新门网络生成的非线性补偿函数, 其输出即为观测误差项 Δz_k ; c_k^h 为当前时刻的观测记忆变量, 用于捕捉传感器误差和观测噪声的时变特性; $\mathcal{N}_c$ 表示观测记忆更新机制. 该机制通过结合当前观测值 z_k 、观测雅可比矩阵 H_k (即观测函数在 x_k 处的局部梯度信息) 以及从原始 sEMG 数据中提取的肌电特征 i_k^{emg} , 旨在动态调整记忆内容, 从而提升对观测模型误差的适应能力.

为实现运动模型误差与观测模型误差的建模与解耦, 引入预测记忆变量 c_k^f 与观测记忆变量 c_k^h 这两种独立的记忆变量. 其中, 预测记忆变量 c_k^f 用于补偿状态转移过程中的长期依赖性所带来的模型偏差; 而观测记忆变量 c_k^h 则用于修正由传感器特性及观测噪声所导致的测量误差. 这种解耦建模策略能够对复杂的模型误差来源进行精细化的辨识与补偿, 从而提升系统整体的鲁棒性与估计精度.

为挖掘原始观测数据的深层次特征, 利用 ECA (efficient channel attention) 特征提取网络从原始观测数据中提炼出肌电特征信息 i_k^{emg} , 并建模如下

$$i_k^{emg} = g^\theta(o_k) \quad (7)$$

其中, $g^\theta(\cdot)$ 为特征提取网络, θ 表示该网络的可学习参数; o_k 表示在时刻 k 采集的滑动窗口内的原始多通道 sEMG 矩阵.

为了便于在贝叶斯滤波框架下进行概率推理, 假设预测记忆变量 c_k^f 与观测记忆变量 c_k^h 服从高斯分布, 其一阶矩与二阶矩分别为 $\hat{c}_k^f$ 、 $\hat{c}_k^h$ 和 P_k^{cf} 、 P_k^{ch} , 即

$$p(c_k^f|x_{k-1}, F_k, c_{k-1}^f) = \mathcal{N}(c_k^f; \hat{c}_k^f, P_k^{cf}) \quad (8)$$

$$p(c_k^h|z_k, H_k, c_{k-1}^h, i_k^{emg}) = \mathcal{N}(c_k^h; \hat{c}_k^h, P_k^{ch}) \quad (9)$$

其中, $p(\cdot)$ 表示概率密度函数. 同时, 模型误差补偿项 Δx_k 与观测误差补偿项 Δz_k 分别服从高斯分布, 其一阶矩和二阶矩分别为

$$p(\Delta x_k|c_k^f) = \mathcal{N}(\Delta x_k; \Delta \hat{x}_k, \Delta Q_k) \quad (10)$$

$$p(\Delta z_k|x_k, c_k^h) = \mathcal{N}(\Delta z_k; \Delta \hat{z}_k, \Delta R_k) \quad (11)$$

其中, $\Delta \hat{x}_k$ 和 ΔQ_k 分别为模型误差补偿项的均值与协方差; $\Delta \hat{z}_k$ 和 ΔR_k 分别为观测误差补偿项的均值与协方差.

2 运动估计方法

本文所提 GPGF-net 的框架如图 1 和图 2 所示. GPGF-net 通过引入独立的状态预测门和状态

更新门, 以“分而治之”的策略来处理基于 sEMG 的肢体运动估计任务. 在状态预测门中, 预测记忆更新器与预测协方差评估器通过更新记忆变量 c_k^f 及其协方差 P_k^{cf} 来捕捉状态演化的时间规律, 状态预测门结合先验系统模型与学习补偿项, 对系统模型误差进行补偿; 在状态更新门中, 观测记忆更新器与观测协方差评估器通过更新记忆变量 c_k^h 及其协方差 P_k^{ch} 来捕捉观测信号演化的时间规律, 状态更新门通过渐进高斯近似更新方式来实现观测融合, 从而同步补偿观测模型的非线性误差. 最后, 门控渐进高斯滤波网络使用真值与估计值 $\hat{x}_{k|k}$ 的偏差来优化滤波网络的权重参数, 从而从离线数据中学习得出各门控机制的记忆迭代规律 $\mathcal{M}_c$ 、 $\mathcal{N}_c$ 以及预测补偿 Δx_k 与观测补偿 Δz_k 的分布参数.




图 1 GPGF-net 总体框架

Fig.1 Overall framework of GPGF-net

2.1 状态预测门: 运动模型误差补偿

状态预测门用于动态补偿系统状态转移模型 $f(\cdot)$ 的预测误差 Δx_k 和预测误差协方差 ΔQ_k , 进而计算先验概率密度

$$p(x_k|z_{1:k-1}) = \int I_k p(x_{k-1}|z_{1:k-1}) dx_{k-1} \quad (12)$$

其中, $z_{1:k-1} = \{z_1, z_2, \dots, z_{k-1}\}$ 为 1 到 $k-1$ 时刻的所有观测. 积分项 I_k 可分解为系统模型与门控补偿的联合分布

$$I_k = \int \underbrace{p(x_k|x_{k-1}, \Delta x_k)}_{\text{系统模型}} \underbrace{p(\Delta x_k|x_{k-1})}_{\text{门控补偿}} d\Delta x_k \quad (13)$$

传统非线性滤波方法通常依赖线性化假设或蒙特卡洛方法, 这将难以处理 sEMG 模型误差. GPGF-net 引入预测记忆变量 c_k^f 和观测记忆变量 c_k^h , 同时通过记忆更新器和协方差评估器递归地学习并估计这两个变量的条件均值与协方差. 所获取的均




图 2 门控渐进高斯滤波网络结构

Fig. 2 Architecture of the gated progressive Gaussian filtering network

值与协方差随后被用来确定系统模型误差补偿项 Δx_k 和观测模型误差补偿项 Δz_k 的概率分布, 从而实现对模型误差的补偿. 对于系统 (1), 在假设 (8)~(11) 成立的前提下, 本文采用无迹变换 (unscented transformation, UT) 生成 $2n+1$ 个 Sigma 点集 $\{\chi_{k-1|k-1}^{(i)}\}_{i=0}^{2n}$ (n 为状态维度). Sigma 点的生成及权重计算公式如下

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

$$W_i^m = W_i^c = \begin{cases} \frac{\kappa}{n+\kappa}, & i = 0 \\ \frac{1}{2(n+\kappa)}, & i = 1, \dots, 2n \end{cases} \quad (15)$$

其中, W_i^m 与 W_i^c 分别为用于计算均值和协方差的无迹变换权重; $\hat{x}_{k-1|k-1}$ 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 的维数; $(\cdot)_i$ 表示矩阵的第 i 列; κ 为比例因子, 设置为 $\kappa = 3 - n$ (详见文献 [29]). Sigma 点经状态转移函数进行传播并叠加补偿项的一阶矩 $\Delta \hat{x}_k$, 得到传播后的点 $\chi_{k|k-1}^{(i)}$ 为

$$\chi_{k|k-1}^{(i)} = f(\chi_{k-1|k-1}^{(i)}) + \Delta \hat{x}_k, \quad i = 0, \dots, 2n \quad (16)$$

修正后的先验均值与协方差为

$$\begin{aligned} \hat{x}_{k|k-1} &= E[x_k | z_{1:k-1}] = \\ &\iint (f(x_{k-1}) + \Delta x_k) p(\Delta x_k, x_{k-1} | z_{1:k-1}) \\ &\mathrm{d}\Delta x_k \mathrm{d}x_{k-1} = \\ &\iiint (f(x_{k-1}) + \Delta x_k) p(\Delta x_k | c_k^f) p(c_k^f | x_{k-1}, \\ &F_k, c_{k-1}^f) p(x_{k-1}, F_k, c_{k-1}^f | z_{1:k-1}) \\ &\mathrm{d}\Delta x_k \mathrm{d}c_k^f \mathrm{d}x_{k-1} = \\ &\int f(x_{k-1}) N(x_{k-1}; \hat{x}_{k-1|k-1}, P_{k-1|k-1}) \mathrm{d}x_{k-1} + \\ &\Delta \hat{x}_k \approx \sum_{i=0}^{2n} W_i^m \chi_{k|k-1}^{(i)} \end{aligned} \quad (17)$$

$$\begin{aligned} P_{k|k-1} &= E[(x_k - \hat{x}_{k|k-1})(x_k - \hat{x}_{k|k-1})^T] = \\ &E[(f(x_{k-1}) - E[f(x_{k-1})])(f(x_{k-1}) - \\ &E[f(x_{k-1})])^T] + \\ &\underbrace{E[(\Delta x_k - \Delta \hat{x}_k)(\Delta x_k - \Delta \hat{x}_k)^T]}_{\text{状态转移协方差}} + \\ &\underbrace{E[(\Delta x_k - \Delta \hat{x}_k)(\Delta x_k - \Delta \hat{x}_k)^T]}_{\text{预测误差协方差}} + \\ &\underbrace{E[w_k w_k^T]}_{\text{过程噪声协方差}} \approx \\ &\sum_{i=0}^{2n} W_i^c f(\chi_{k-1|k-1}^{(i)}) f^T(\chi_{k-1|k-1}^{(i)}) - \\ &\hat{x}_{k|k-1} \hat{x}_{k|k-1}^T + Q_k + \Delta Q_k \end{aligned} \quad (18)$$

式 (18) 给出了噪声协方差的构成, 即由预设的先验基准值 Q_k 和网络动态生成的补偿项 ΔQ_k 相加而成. 这里, Q_k 代表对系统噪声的简化或理想化假设, 其值通常根据经验预设为固定值. 针对未建模噪声特性, 由状态预测协方差补偿模块进行学习并输出动态补偿项 ΔQ_k , 从而实现对 Q_k 的自适应修正. 补偿项 $\Delta \hat{x}_k$ 和 ΔQ_k 分别由状态预测补偿模块 $F_1(i) = W_2(\tanh(W_1 i + b_1)) + b_2$ 和状态预测协方差补偿模块 $F_2(i) = \exp(W_2(\sigma(W_1 i + b_1)) + b_2)$ 输出, 用以修正状态转移的非线性偏差并量化补偿项的统计特性.

$$\Delta \hat{x}_k = F_1(i_k^f) = W_2(\tanh(W_1 i_k^f + b_1)) + b_2 \quad (19)$$

$$\Delta Q_k = F_2(i_k^f) = \exp(W_2(\sigma(W_1 i_k^f + b_1)) + b_2) \quad (20)$$

其中, W_1 和 W_2 分别是网络各层的权重矩阵; σ 为 sigmoid 函数; b_1 和 b_2 是对应的偏置向量. 这些参数均通过网络训练学习得到. 状态预测补偿模块与状态预测协方差补偿模块的共同输入特征 i_k^f 由预测记忆变量的一阶矩和二阶矩拼接而成, 即

$$i_k^f = \sigma(\hat{c}_k^f \parallel \text{flat}(P_k^{cf})) \quad (21)$$

其中, “ $\parallel$ ”表示向量拼接; $\text{flat}(\cdot)$ 为矩阵展平操作.

预测记忆更新器与预测协方差评估器通过神经网络 F_1 和 F_2 来生成预测记忆变量 c_k^f 的一阶矩和二阶矩

$$\hat{c}_k^f = F_1(i_k^{cf}) = W_2(\tanh(W_1 i_k^{cf} + b_1)) + b_2 \quad (22)$$

$$P_k^{cf} = F_2(i_k^{cf}) = \exp(W_2(\sigma(W_1 i_k^{cf} + b_1)) + b_2) \quad (23)$$

门控网络通过递归设计更新预测记忆变量 c_k^f , 用以捕捉状态演化过程中的长期时间依赖特性. 预测记忆变量 c_k^f 由预测记忆更新器 $\mathcal{M}_c$ 生成, 其输入包含状态演化差异 $\Delta \check{x}_k = f(\hat{x}_{k-1|k-1}) - \hat{x}_{k-1|k-1}$ 、雅可比矩阵 $F_k = \frac{\partial f}{\partial x}|_{\hat{x}_{k-1|k-1}}$ 以及上一时刻预测记忆变量 c_{k-1}^f . 预测记忆更新器与预测协方差评估器的输入特征 i_k^{cf} 通过拼接 $\hat{c}_{k-1}^f$ 、 F_k 、 $\Delta \check{x}_k$ 来构建, 即

$$i_k^{cf} = \sigma(\hat{c}_{k-1}^f \parallel \text{flat}(P_{k-1}^{cf}) \parallel \Delta \check{x}_k \parallel \text{flat}(F_k)) \parallel \Psi(\hat{x}_{k-1|k-1}) \quad (24)$$

式 (24) 通过 sigmoid 函数 $\sigma(\cdot)$ 约束特征范围, 并采用 Min-Max 归一化函数 $\Psi(\cdot)$ 将输入数据缩放到 $[0, 1]$ 区间, 以消除量纲差异, 形成紧凑的输入特征 i_k^{cf} .

这样, 预测门内部形成物理模型、残差计算、记忆更新和补偿生成的闭环反馈机制, 通过雅可比矩阵 F_k 传递状态转移的局部梯度信息, 并结合预测

残差 $\Delta \check{x}_k$ 作为反馈信号来动态调整记忆变量的遗忘与更新权重. 这种设计使得先验模型知识与数据驱动特征在贝叶斯滤波框架下的相容性增加, 从而提升对模型误差的鲁棒性.

2.2 状态更新门: 基于观测模型补偿的渐进更新

状态更新门通过渐进观测更新来补偿观测模型 $h(\cdot)$ 的非线性误差, 进而计算后验概率密度

$$p(x_k | z_{1:k}) = \frac{p(z_k | x_k) p(x_k | z_{1:k-1})}{p(z_k | z_{1:k-1})} \quad (25)$$

其中, 似然项 $p(z_k | x_k)$ 可分解为观测模型与观测误差补偿项的联合分布

$$p(z_k | x_k) = \int \underbrace{p(z_k | x_k, \Delta z_k)}_{\text{观测模型}} \underbrace{p(\Delta z_k | x_k)}_{\text{门控补偿}} d\Delta z_k \quad (26)$$

传统卡尔曼滤波方法通常基于单步观测更新机制, 即在先验状态分布的基础上通过一步观测更新来计算后验分布. 这类方法依赖于高斯假设下的解析近似, 且未显式地引入模型误差补偿机制, 使得存在未建模动态时, 状态估计精度下降明显. 本文所设计的 GPGF-net 采用渐进式观测更新策略, 将单次观测更新分解为 N 个子过程. 如图 3 所示, 该策略通过分步观测更新来逐步逼近真实后验分布; 同时, 通过观测补偿模块来动态修正模型误差 Δz_k 并调整协方差 ΔR_k , 从而抑制线性化近似误差的累积, 使得 GPGF-net 能鲁棒地应对模型误差问题. 通过增大观测噪声协方差 R_k 将减小卡尔曼增益 $K_k \propto (H_k P_{k|k-1} H_k^T + R_k)^{-1}$, 降低估计器对当前观测的依赖, 从而抑制离群值或模型失配引起的估计发散以提升稳定性^[21]. 然而, 其代价是降低对系统动态的响应速度, 若长期维持过大的 R_k , 则会导致估计滞后. 为此, 本文采用渐进更新策略来增大 R_k . 该方法平滑了更新过程, 使得每个子步骤都以稳健的小增益修正状态, 即通过多步迭代充分融合观测信息, 从而在获得滤波稳定性的同时避免长期性能下降风险. 在该策略中, 步数 N 的选择需权衡计算成本与精度. 令渐进更新的伪时间点为 $\lambda_i \in [0, 1]$,




图 3 补偿渐进观测更新

Fig. 3 Compensated progressive observation update

$i = 0, 1, \dots, N$, 第 i 步伪时间点 $\lambda_i = \lambda_{i-1} + \Delta_i$, 且满足 $\lambda_0 = 0$ 和 $\lambda_N = 1$, 其中 Δ_i 表示第 i 步的迭代步长. 根据贝叶斯准则, 伪时间 λ_{i+1} 对应的渐进后验概率密度函数为

$$p(x_k | \lambda_{i+1}, z_k, z_{1:k-1}) = p(x_k | \lambda_i + \Delta_{i+1}, z_k, z_{1:k-1}) = \frac{p(z_k, \Delta_{i+1} | x_k) p(x_k | \lambda_i, z_{1:k-1})}{\int p(z_k, \Delta_{i+1} | x_k) p(x_k, \lambda_i | z_{1:k-1}) dx_k} \quad (27)$$

值得一提的是, 贝叶斯滤波器是一种递归估计未知概率密度函数 (probability density function, PDF) 的方法. 为将 PDF 的迭代简化为均值和协方差的迭代, 假设渐进联合 PDF 是高斯的, 即

$$p(x_k, z_k, \lambda_i | z_{1:k-1}) \approx \hat{p}(x_k, z_k, \lambda_i | z_{1:k-1}) = N \left(\begin{bmatrix} x_k \\ z_k \end{bmatrix}; \begin{bmatrix} \hat{x}_{k|k, \lambda_{i-1}} \\ \hat{z}_{k|k, \lambda_i} \end{bmatrix}, \begin{bmatrix} P_{k|k, \lambda_{i-1}} & P_{xz, k|k, \lambda_i} \\ (P_{xz, k|k, \lambda_i})^T & P_{zz, k|k, \lambda_i} \end{bmatrix} \right) \quad (28)$$

其中, $\hat{p}(\cdot)$ 表示近似的联合概率密度函数; $\hat{z}_{k|k, \lambda_i}$ 为观测预测均值; $P_{zz, k|k, \lambda_i}$ 为观测预测协方差; $P_{xz, k|k, \lambda_i}$ 为状态与观测的互协方差. 这样, 伪时间点 λ_i 的后验 PDF 可以表示为

$$p(x_k, z_k, \lambda_i | z_{1:k-1}) \approx \hat{p}(x_k, z_k, \lambda_i | z_{1:k-1}) = N(x_k; \hat{x}_{k|k, \lambda_i}, P_{k|k, \lambda_i}) \quad (29)$$

其中, $\hat{x}_{k|k, \lambda_i}$ 和 $P_{k|k, \lambda_i}$ 分别为伪时间点 λ_i 的渐进状态估计值及其协方差. 在渐进观测更新中, 取渐进均值补偿量为 $\Delta \hat{z}_{k, \lambda_i} = \Delta \hat{z}_k / N$, 并依据式 (14) 和式 (15) 定义的 UT 方法生成 Sigma 点集合 $\{\chi_{k|k, \lambda_{i-1}}^{(j)}\}_{j=0}^{2n}$, 将其通过观测函数可得观测预测 Sigma 点集合 $Z_{k|k, \lambda_i}^{(j)}$, 即

$$Z_{k|k, \lambda_i}^{(j)} = h(\chi_{k|k, \lambda_{i-1}}^{(j)}) + \Delta \hat{z}_{k, \lambda_i}, j = 0, 1, \dots, 2n \quad (30)$$

进而, 可得观测预测

$$\begin{aligned} \hat{z}_{k|k, \lambda_i} &= E[z_k, \lambda_i | z_{1:k-1}] = \int h(x_k) p(x_k | z_{1:k-1}) dx_k + \\ &\int \Delta z_{k, \lambda_i} p(\Delta z_{k, \lambda_i} | x_k) d\Delta z_{k, \lambda_i} = \\ &\int h(x_k) N(x_k; \hat{x}_{k|k, \lambda_{i-1}}, P_{k|k, \lambda_{i-1}}) dx_k + \\ &\Delta \hat{z}_{k, \lambda_i} \approx \sum_{j=0}^{2n} W_j^m Z_{k|k, \lambda_i}^{(j)} \end{aligned} \quad (31)$$

同时, 取渐进协方差补偿量 $\Delta R_{k, \lambda_i} = \Delta R_k / N$, 则观测预测协方差为

$$\begin{aligned} P_{zz, k|k, \lambda_i} &= E[(z_k, \lambda_i - \hat{z}_{k|k-1, \lambda_i}) \times \\ &(z_k, \lambda_i - \hat{z}_{k|k-1, \lambda_i})^T] = \\ &E[(h(x_k, \lambda_i) - E[h(x_k, \lambda_i)])(h(x_k, \lambda_i) - \\ &E[h(x_k, \lambda_i)])^T] + \\ &\underbrace{E[(\Delta z_{k, \lambda_i} - \Delta \hat{z}_{k, \lambda_i})(\Delta z_{k, \lambda_i} - \Delta \hat{z}_{k, \lambda_i})^T]}_{\text{观测模型协方差}} + \\ &\underbrace{E[v_{k, \lambda_i} v_{k, \lambda_i}^T]}_{\text{观测噪声协方差}} = \\ &\iint (z_k - \hat{z}_{k|k, \lambda_i})(z_k - \hat{z}_{k|k, \lambda_i})^T p(x_k, z_k, \lambda_i | \\ &z_{1:k-1}) dz_k dx_k + \Delta R_{k, \lambda_i} \approx \\ &\sum_{j=0}^{2n} W_j^c h(\chi_{k|k, \lambda_{i-1}}^{(j)}) h^T(\chi_{k|k, \lambda_{i-1}}^{(j)}) - \\ &\hat{z}_{k|k, \lambda_i} \hat{z}_{k|k, \lambda_i}^T + \frac{R_k}{\Delta_i} + \Delta R_{k, \lambda_i} \end{aligned} \quad (32)$$

与过程噪声协方差类似, 式 (32) 中总的观测噪声协方差由经步长 Δ_i 缩放先验基准值 R_k 和动态补偿项 $\Delta R_{k, \lambda_i}$ 共同构成. 状态与观测的互协方差为

$$\begin{aligned} P_{xz, k|k, \lambda_i} &= E[(x_k - \hat{x}_{k|k, \lambda_{i-1}})(z_k - \hat{z}_{k|k, \lambda_i})^T] \approx \\ &\sum_{j=0}^{2n} W_j^c (\chi_{k|k, \lambda_{i-1}}^{(j)} - \hat{x}_{k|k, \lambda_{i-1}}) \times \\ &(Z_{k|k, \lambda_i}^{(j)} - \hat{z}_{k|k, \lambda_i})^T \end{aligned} \quad (33)$$

$$\hat{x}_{k|k, \lambda_i} = \hat{x}_{k|k, \lambda_{i-1}} + K_{k, \lambda_i} (z_k - \hat{z}_{k|k, \lambda_i}) \quad (34)$$

$$P_{k|k, \lambda_i} = P_{k|k, \lambda_{i-1}} - P_{xz, k|k, \lambda_i} P_{zz, k|k, \lambda_i}^{-1} P_{xz, k|k, \lambda_i}^T \quad (35)$$

其中, $K_{k, \lambda_i} = P_{xz, k|k, \lambda_i} P_{zz, k|k, \lambda_i}^{-1}$ 为渐进式滤波增益. 上述式中, 观测补偿项 $\Delta \hat{z}_k$ 由观测模型补偿模块 F_1 输出, 用于修正观测方程的非线性误差; ΔR_k 由观测误差协方差补偿模块 F_2 输出, 以增强模型对未建模动态的鲁棒性. 即

$$\Delta \hat{z}_k = F_1(i_k^h) = W_2(\tanh(W_1 i_k^h + b_1)) + b_2 \quad (36)$$

$$\Delta R_k = F_2(i_k^h) = \exp(W_2(\sigma(W_1 i_k^h + b_1)) + b_2) \quad (37)$$

其中, 上述观测模型与协方差补偿模块的输入特征 i_k^h 通过拼接观测记忆变量的一阶矩和二阶矩来

构建

$$i_k^h = \sigma(\hat{c}_k^h \parallel \text{flat}(P_k^{ch})) \quad (38)$$

观测记忆更新器与观测协方差评估器通过神经网络 F_1 和 F_2 来生成观测记忆变量 c_k^h 的一阶矩和二阶矩

$$\hat{c}_k^h = F_1(i_k^{ch}) = W_2(\tanh(W_1 i_k^{ch} + b_1)) + b_2 \quad (39)$$

$$P_k^{ch} = F_2(i_k^{ch}) = \exp(W_2(\sigma(W_1 i_k^{ch} + b_1)) + b_2) \quad (40)$$

门控网络通过递归更新观测记忆变量 c_k^h 来捕捉观测噪声的时变特性. 观测记忆变量 c_k^h 由观测记忆更新器 $\mathcal{N}_c$ 生成, 其输入包含新息 $\Delta \hat{z}_k = z_k - h(\hat{x}_{k|k-1})$ 、观测函数的雅可比矩阵 $H_k = \frac{\partial h}{\partial x}|_{\hat{x}_{k|k-1}}$ 、时间窗口肌电特征信息 i_k^{emg} 以及上一时刻观测记忆变量 c_{k-1}^h . 观测记忆更新器与观测协方差评估器的输入特征 i_k^{ch} 通过拼接 $\Delta \hat{z}_k$ 、 H_k 、 i_k^{emg} 、 $\hat{c}_{k-1}^h$ 等来构建

$$i_k^{ch} = \sigma(\hat{c}_{k-1}^h \parallel \text{flat}(P_{k-1}^{ch}) \parallel \Delta \hat{z}_k \parallel \text{flat}(H_k) \parallel i_k^{emg}) \parallel \Psi(\hat{x}_{k|k-1}) \quad (41)$$

通过上述渐进式更新机制, 门控网络可动态调整补偿项 $\Delta \hat{z}_k$ 与 ΔR_k 的分布参数, 通过分步观测更新来逐步逼近真实后验分布. 门控高斯网络滤波算法如算法 1 所示.

算法 1. 门控高斯网络滤波算法

- 1) 初始化
- 2) **while** true **do**
- 3) 预测记忆更新 c_k^f ; 计算状态预测补偿项 $\Delta \hat{x}_k, \Delta Q_k$
- 4) 时间更新: 式 (16)~(18)
- 5) 观测记忆更新 c_k^h ; 计算状态更新补偿项 $\Delta \hat{z}_k, \Delta R_k$
- 6) **for** $j = 1 : N$ **do**
- 7) 观测更新: 式 (30)~(35)
- 8) **end for**
- 9) **end while**

2.3 联合优化损失函数设计

为实现门控渐进高斯滤波网络的多目标协同优化, 构建融合“预测-更新”双误差机制的正则化损失函数. 设系统状态为 $x_k \in \mathbf{R}^n$, 神经网络输出的先验预测状态为 $\hat{x}_{k|k-1} \in \mathbf{R}^n$, 经 N 步观测更新后的后验估计状态为 $\hat{x}_{k|k, \lambda_N} \in \mathbf{R}^n$. 定义参数空间为 $\theta = \{W\}$, $W \in \mathbf{R}^{m \times n}$ 为网络权重矩阵. 复合损失函数可表示为

$$\mathcal{L}(\theta) = \underbrace{\frac{1}{T} \sum_{k=1}^T (\alpha \|x_k - \hat{x}_{k|k-1}\|_2^2 + \beta \|x_k - \hat{x}_{k|k, \lambda_N}\|_2^2)}_{\text{动态估计误差}} + \underbrace{\gamma \|W\|_F^2}_{\text{正则化约束}} \quad (42)$$

该损失函数包含动态估计误差和正则化约束两大部分. 其中, 动态估计误差项由先验预测误差 $\|x_k - \hat{x}_{k|k-1}\|_2^2$ 和后验更新误差 $\|x_k - \hat{x}_{k|k, \lambda_N}\|_2^2$ 构成, 前者约束状态预测门对系统状态时间演化的建模能力, 通过最小化真实动力学轨迹与状态预测 $\hat{x}_{k|k-1}$ 之间的欧氏距离来提高预测精度; 后者量化观测更新环节的状态估计偏差, 其中 $\hat{x}_{k|k, \lambda_N}$ 为 N 步观测更新后的后验值. T 表示单个训练样本的时间步长. 正则化约束项 $\|W\|_F^2$ 对网络权重矩阵的 Frobenius 范数施加约束, 其显式表达式为 $\|W\|_F^2 = \sum_{i=1}^m \sum_{j=1}^n W_{ij}^2$, 通过调节系数 $\gamma > 0$ 控制模型复杂度, 有助于抑制参数空间的过拟合风险. 损失函数中的权重系数 α 和 β 用于平衡状态预测门与状态更新门的学习权重. α 的取值反映了对模型预测能力与观测修正能力的相对侧重. 若 α 值较高, 优化过程将更关注于提升状态预测门的长期预测精度, 适用于系统模型较为可靠的场景; 反之, 若 β 值较高, 则更侧重于提升状态更新门对观测信息的即时融合与修正能力.

在本文中, 最优参数的选取是通过网格搜索的方式确定的. 本文在验证集上对 α 的不同取值进行测试, 并以测试集上的均方根误差 (RMSE) 作为最终评判指标. 实验发现, 当 α 取值为 0.4 时, 模型取得了最小的 RMSE, 在预测稳定性与观测跟随性之间达到最佳平衡. 因此, 本文所有实验均采用 $\alpha = 0.4$, $\beta = 0.6$ 的配置.

3 实验

为验证该滤波算法的有效性, 本文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, 基于所提出的 GPGF-net 方法与其他对比方法进行肢体运动估计, 从而验证模型的有效性.

3.1 数据采集

本实验平台由生物电信号采集与三维运动捕捉两大模块组成, 同步采集 sEMG 与运动学参数, 整体数据采集场景如图 4(a) 所示. 生物电信号采集模块采用 Myo 无线臂环 (Version 2.0) 作为传感设备, 该设备以 200 Hz 采样率同步获取右上臂 8 通道




图 4 实验系统与设备布置 ((a) 数据采集场景;
(b) 传感器佩戴布局)

Fig.4 Experimental system and equipment setup ((a)
Data acquisition scenario; (b) Sensor placement layout)

sEMG, 信号采集范围覆盖肱二头肌、肱三头肌等肘关节屈伸运动相关肌群. 为确保信号采集稳定性, 臂环佩戴位置经预先实验优化, 使其电极阵列紧密贴合目标肌群表面.

运动学参数采集采用 OptiTrack 光学运动捕捉系统, 配置 12 台高速红外相机组成捕捉阵列. 为提高关节角度计算精度, 在受试者肱骨远端 (大臂段) 和尺骨近端 (小臂段) 分别布置 4 枚主动式光学标记点, 构建刚体坐标系. 通过实时解算两刚体坐标系的空间向量投影 (图 4(b) 中的 $\overrightarrow{AB}$ 与 $\overrightarrow{BC}$ 向量), 以向量夹角反演肘关节三维运动角度, 该方法的冗余标记设计可解决单点遮挡导致的运动轨迹丢失问题.

实验招募 12 名健康且惯用右手的受试者, 在温度恒定的实验室环境中执行标准化肘关节运动协议. 受试者站立于 8 m × 8 m 捕捉区域中心位点, 按视觉引导完成 4 组复合屈伸动作: 初始位手臂自然下垂, 以自主选择的舒适速度屈肘至生理极限角度, 保持静态姿势 2 s 后匀速伸展复位. 每组包含 10 次完整屈伸周期, 实验分两个阶段进行, 间隔 15 min 恢复期以消除肌肉疲劳效应. 整个采集过程持续约 32 min, 同步记录到有效 sEMG-角度配对数据样本量达 480 组.

3.2 实验模型

基于 Han 等^[17] 提出的状态空间机电模型, 本文采用以下非线性状态方程描述 sEMG 与关节运动状态的动态关系. 运动模型可表述如下

$$f(x_k, a_k) = \begin{bmatrix} (s_0 + s_1\theta_k + s_2\dot{\theta}_k^2)a_k + s_3e^{s_4\theta_k} - s_5\sin(\theta_k) \\ \dot{\theta}_k + \ddot{\theta}_k T_s \\ \theta_k + \dot{\theta}_k T_s \end{bmatrix} \quad (43)$$

其中, 状态向量为 $x_k = [\theta_k, \dot{\theta}_k, \ddot{\theta}_k]^T$, θ_k 、 $\dot{\theta}_k$ 和 $\ddot{\theta}_k$ 分别表示肘关节在时刻 k 的关节角度、角速度和

角加速度; 输入 a_k 为肌肉激活度; T_s 为系统采样时间; $s_0 \sim s_5$ 为与生物力学特性相关的常数, 通过离线数据标定获得. 观测模型可表述如下

$$h(x_k) = \begin{bmatrix} c_0^1 + c_1^1\dot{\theta}_k + c_2^1\theta_k + c_3^1\dot{\theta}_k^2 + c_4^1\theta_k^2 + c_5^1\dot{\theta}_k\theta_k \\ c_0^2 + c_1^2\dot{\theta}_k + c_2^2\theta_k + c_3^2\dot{\theta}_k^2 + c_4^2\theta_k^2 + c_5^2\dot{\theta}_k\theta_k \end{bmatrix} \quad (44)$$

观测值为 sEMG 的波形长度和过零率, $c_0^j \sim c_5^j$ ($j = 1, 2$) 为肌电信号特征与运动状态的映射系数, 通过肌电信号的波形长度、过零率与关节状态的二阶多项式拟合确定.

4 实验结果

4.1 特征提取

本文设计基于高效通道注意力机制 (ECA) 的肌电特征提取模块, 架构如图 5 所示.




图 5 特征提取模块

Fig.5 Feature extraction module

输入数据经滑动窗口处理得到 $L \times C$ 维肌电矩阵 (L 表示滑动窗口长度, C 表示采集通道数). 网络的特征提取具体配置依次为: 首先经过 3×1 且步长为 1 的 16 通道一维卷积层; 随后输入 $K = 3$ 的自适应 ECA 模块, 通过通道注意力权重动态强化关键肌电模式; 接着经过窗口为 3 的一维最大池化进行特征压缩; 其后再次连接 3×1 且步长为 1 的 32 通道一维卷积层; 最终, 32 维特征经批归一化与概率为 0.3 的 Dropout 层防止过拟合处理后, 通过特征维度为 20 的全连接层映射至肌电特征向量 i_k^{emg} , 作为 GPFG-net 的输入. 图中 o_k 为窗口内原始肌电数据, i_k^{emg} 表征经 ECA 优化的特征向量.

4.2 实验设置与结果分析

在实验中所有设计模型均基于 Python 3.9 实现, 通过 PyTorch 1.12 框架搭建, 并在英特尔 i7-10700K 处理器和 NVIDIA RTX 4070 显卡上完成训练. 模型总训练轮次为 90 轮, 每轮迭代的批次大小为 32 个样本, 采用 Adam 优化器 ($\beta_1 = 0.9$,

$\beta_2 = 0.999$). ECA 肌电特征提取模块初始学习率为 0.001, 每 20 轮衰减为原值的 50%; 运动估计网络 (GPGF-net) 采用默认初始化权重, 初始学习率为 0.001, 每 10 轮通过乘数 0.8 进行学习率衰减. 此外, 针对模型中的渐进观测更新策略, 经敏感性分析, 当 $N > 10$ 后精度提升不显著, 故本文设定 $N = 10$ 并采用均匀步长. 数据集按 60% 训练集和 40% 测试集划分, 所有对比实验均统一采用相同超参数配置以保证公平性.

本文采用相关系数 (R^2) 和均方根误差 (RMSE) 作为评价指标对滤波网络模型进行评估, 并统计各网络模型的浮点运算数 (FLOPs) 和参数数量 (Params). 其中, RMSE 用于量化估计值与真值之间的幅值差异, 而 R^2 则用于衡量滤波估计值的曲线与关节运动真值的相关程度. 以受试者 S1 和 S2 的测试数据为样本, 图 6 展示了五种基于 sEMG 人体运动估计模型输出肘关节角度曲线以及误差曲线的对比结果. 实验表明, 五种方法都可以从表面肌电信号中有效地重建肘关节运动. 如图 6 所示, 不难发现肌电信号通过 GPGF-net 估计的肘关节角度比其他四种方法的估计值更接近真实值. 特别地, EKF 方法的估计角度曲线与真值曲线误差值较大, 是由于预设的刚体运动学模型未考虑软组织形变、关节润滑度变化等时变生物力学特性, 导致状态转移方程与实际运动之间存在误差. TCN-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. 得益于学习型卡尔曼滤波的鲁棒性, PUKF-net (progressive unscented Kalman filter net-

work) 和 GPGF-net 的预测值波动平缓, GPGF-net 整体上更接近真实值.

为对不同方法的估计精度进行量化评估, 表 1 总结了五种方法在所有受试者中的相关系数和均方根误差. 从图 7 中可以直观地看出, 与其他四种模型相比, GPGF-net 通过门控记忆单元补偿模型误差和渐进观测更新, 提高了模型的精度和稳定性. 相较于 LSTM-KF 模型而言, GPGF-net 在肘关节角度估计中的 RMSE 平均下降约 15.62%, 相关系数平均提高约 5.08%. 为评估各网络模型的计算复杂度与实际运行效率, 本文统计了四种模型的 FLOPs 和 Params, 并对各模型在测试平台上进行单步平均推理速度测试. 如表 2 所示, 本文提出的 GPGF-net 在各项复杂度指标上均为最低, 其平均推理耗时为 0.811 ms. 考虑到其较低的 FLOPs 和 Params, 通过模型量化与剪枝等优化手段, GPGF-net 具备在高性能嵌入式平台 (如 NVIDIA Jetson 系列) 上部署的潜力.

4.3 鲁棒性分析

为评估 GPGF-net 对噪声干扰的鲁棒性, 本文在测试数据集的原始 sEMG 中注入零均值高斯白噪声, 噪声水平通过信噪比 (SNR) 量化: $SNR = 10 \lg(P_{\text{signal}}/P_{\text{noise}})$, 其中 P_{signal} 和 P_{noise} 分别为信号与噪声功率. 实验选取无噪声、15 dB 和 10 dB 三种水平, 对所有受试者数据重复测试, 使用相同模型参数设置 (详见第 4.2 节). 仅对比 GPGF-net 与 LSTM-KF 的性能, 计算平均 RMSE 和 R^2 , 结果如表 3 所示.




图 6 角度估计和误差曲线
Fig.6 Angle estimation and error curves

表 1 模型性能评价
Table 1 Evaluation of model performances

测试者	RMSE					R ²				
	EKF	TCN-LSTM	LSTM-KF	PUKF-net	GPGF-net	EKF	TCN-LSTM	LSTM-KF	PUKF-net	GPGF-net
S1	20.332	16.632	13.654	12.940	11.349	0.753	0.823	0.892	0.906	0.920
S2	22.351	22.787	18.678	16.980	15.436	0.622	0.631	0.765	0.824	0.846
S3	20.662	20.735	16.996	15.434	14.031	0.718	0.712	0.821	0.842	0.876
S4	18.624	17.238	14.353	13.048	11.851	0.772	0.811	0.886	0.898	0.910
S5	20.648	20.895	20.366	18.502	17.995	0.710	0.699	0.750	0.765	0.765
S6	22.992	16.642	13.644	12.956	11.778	0.614	0.821	0.898	0.905	0.913
S7	19.965	17.965	17.164	15.669	14.245	0.721	0.802	0.819	0.836	0.872
S8	18.356	17.356	15.241	13.958	12.689	0.776	0.815	0.853	0.886	0.903
S9	20.162	19.235	18.468	16.753	15.256	0.718	0.754	0.774	0.828	0.842
S10	20.169	21.240	18.655	17.235	15.658	0.716	0.657	0.770	0.795	0.802
S11	21.362	20.109	17.869	15.668	14.245	0.651	0.723	0.782	0.832	0.870
S12	18.623	15.543	13.458	12.487	11.351	0.770	0.843	0.901	0.909	0.914
均值	21.462	19.698	16.504	15.376	13.926	0.710	0.751	0.827	0.844	0.869
标准差	3.297	3.533	2.494	1.925	2.145	0.057	0.072	0.053	0.047	0.049




图 7 五个模型的 RMSE 和 R²
Fig. 7 RMSE and R² of the five models

表 2 四种模型的计算复杂度与性能
Table 2 The computational complexity and performance of four models

	TCN-LSTM	LSTM-KF	PUKF-net	GPGF-net
FLOPs	912 186	1 219 448	719 448	699 656
Params	320 133	342 337	256 511	245 718
推理时间 (ms)	1.096	1.469	0.865	0.811

从表 3 可见, 随着噪声增加, 两种方法的性能均下降, 但 GPGF-net 的降幅较小 (如 SNR = 10 dB 时, GPGF-net 的 RMSE 相较无噪声仅增加约 27.2%, 而 LSTM-KF 增加约 32.5%), 这得益于其门控记忆机制和渐进更新策略能更好地抑制噪声干扰. 该分析验证了 GPGF-net 在噪声场景下的优越鲁棒性.

5 结束语

针对 sEMG 模型与人体运动模型误差导致的

表 3 不同信噪比下的模型性能
Table 3 Model performance under different SNRs

模型	指标	无噪声	SNR = 15 dB	SNR = 10 dB
LSTM-KF	RMSE	16.504	19.236	21.874
	R ²	0.827	0.752	0.677
GPGF-net	RMSE	13.926	15.683	17.721
	R ²	0.869	0.801	0.788

估计性能下降问题, 本文提出门控渐进高斯滤波网络来补偿模型误差以及提升运动估计精度. GPGF-net 通过设计的门控记忆机制学习系统状态的长期依赖与观测信号的时变特性, 动态调整误差补偿项的分布参数以应对模型不确定性. 同时, 引入渐进观测更新策略以减小非线性近似误差和增强模型鲁棒性. 在未来工作中, 将致力于在更大规模、多样化的运动估计任务中验证模型性能, 并将补偿机制拓展至多关节协同建模. 同时将探索在线学习方法, 以增强模型在不同噪声水平、肌肉疲劳等时变干扰下的鲁棒性与泛化能力.

参考文献

- Guo W C, Zhao Z M, Zhou Z Y, Fang Y, Yu Y, Sheng X J. Hand kinematics, high-density sEMG comprising forearm and far-field potentials for motion intent recognition. *Scientific Data*, 2025, **12**(1): Article No. 445
- Hu F, Qian M Y, He K L, Zhang W A, Yang X S. A novel multi-feature fusion network with spatial partitioning strategy and cross-attention for armband-based gesture recognition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, **32**: 3878–3890
- 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
(张望豪, 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)
- 4 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)
 - 5 Buchanan T S, Lloyd D G, Manal K, Besier T F. Neuromusculoskeletal modeling: Estimation of muscle forces and joint moments and movements from measurements of neural command. *Journal of Applied Biomechanics*, 2004, **20**(4): 367–395
 - 6 Sartori M, Reggiani M, Farina D, Lloyd D G. EMG-driven forward-dynamic estimation of muscle force and joint moment about multiple degrees of freedom in the human lower extremity. *PLoS One*, 2012, **7**(12): Article No. e52618
 - 7 Zhao Y H, Zhang Z Q, Li Z H, Yang Z X, Dehghani-Sanij A A, Xie S Q. An EMG-driven musculoskeletal model for estimating continuous wrist motion. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, **28**(12): 3113–3120
 - 8 Tang G, Sheng J Q, Wang D M, Men S. Continuous estimation of human upper limb joint angles by using PSO-LSTM model. *IEEE Access*, 2021, **9**: 17986–17997
 - 9 Zhang Wen-An, Lin An-Di, Yang Xu-Sheng, Yu Li, Yang Xiao-Niu. A survey on Bayesian filtering with deep learning. *Acta Automatica Sinica*, 2024, **50**(8): 1502–1516
(张文安, 林安迪, 杨旭升, 俞立, 杨小牛. 融合深度学习的贝叶斯滤波综述. 自动化学报, 2024, **50**(8): 1502–1516)
 - 10 Avian C, Prakosa S W, Faisal M, Leu J S. Estimating finger joint angles on surface EMG using manifold learning and long short-term memory with attention mechanism. *Biomedical Signal Processing and Control*, 2022, **71**: Article No. 103099
 - 11 Zhao D Z, Ma Y H, Meng J Y, Hu Y, Hong M Q, Zhang J J, et al. MCR-ALS-based muscle synergy extraction method combined with LSTM neural network for motion intention detection. *Frontiers in Neurobotics*, 2023, **17**: Article No. 1174710
 - 12 Chen C, Guo W Y, Ma C F, Yang Y K, Wang Z, Lin C. sEMG-based continuous estimation of finger kinematics via large-scale temporal convolutional network. *Applied Sciences*, 2021, **11**(10): Article No. 4678
 - 13 Fan J, Zhang K, Huang Y P, Zhu Y F, Chen B P. Parallel spatio-temporal attention-based TCN for multivariate time series prediction. *Neural Computing and Applications*, 2023, **35**(18): 13109–13118
 - 14 Hu F, Zhang L K, Yang X S, Zhang W A. EEG-based driver fatigue detection using spatio-temporal fusion network with brain region partitioning strategy. *IEEE Transactions on Intelligent Transportation Systems*, 2024, **25**(8): 9618–9630
 - 15 Wang F J, Liang W Q, Afzal H M R, Fan A, Li W J, Dai X Q, et al. Estimation of lower limb joint angles and joint moments during different locomotive activities using the inertial measurement units and a hybrid deep learning model. *Sensors*, 2023, **23**(22): Article No. 9039
 - 16 Du J L, Liu Z Y, Dong W Y, Zhang W F, Miao Z H. A novel TCN-LSTM hybrid model for sEMG-based continuous estimation of wrist joint angles. *Sensors*, 2024, **24**(17): Article No. 5631
 - 17 Han J D, Ding Q C, Xiong A B, Zhao X G. A state-space EMG model for the estimation of continuous joint movements. *IEEE Transactions on Industrial Electronics*, 2015, **62**(7): 4267–4275
 - 18 Yang Xu-Sheng, Wu Jiang-Yu, Hu Fo, Zhang Wen-An. Multi-view human pose estimation based on progressive Gaussian filtering fusion. *Acta Automatica Sinica*, 2024, **50**(3): 607–616
(杨旭升, 吴江宇, 胡佛, 张文安. 基于渐进高斯滤波融合的多视角人体姿态估计. 自动化学报, 2024, **50**(3): 607–616)
 - 19 Yang X, Zhang W A, Yu L. Fractional Kalman filters. *Automatica*, 2025, **178**: Article No. 112383
 - 20 Miao Z Y, Shi H Y, Zhang Y, Xu F. Neural network-aided variational Bayesian adaptive cubature Kalman filtering for nonlinear state estimation. *Measurement Science and Technology*, 2017, **28**(10): Article No. 105003
 - 21 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
 - 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. 5525–5533
 - 23 Zhao C, Sun L, Yan Z, Neumann G, Duckett T, Stolkin R. Learning Kalman network: A deep monocular visual odometry for on-road driving. *Robotics and Autonomous Systems*, 2019, **121**: Article No. 103234
 - 24 Liu J X, Wang Z L, Xu M. DeepMTT: A deep learning maneuvering target-tracking algorithm based on bidirectional LSTM network. *Information Fusion*, 2020, **53**: 289–304
 - 25 Yang X S, Yin S, Zhang W A, Hu F, Yu L. Asynchronous Gaussian filtering fusion for human motion estimation based on RGB-D cameras. *IEEE Sensors Journal*, 2023, **23**(22): 28044–28054
 - 26 Yang Xu-Sheng, Li Fu-Xiang, Hu Fo, Zhang Wen-An. Human motion estimation based on EMG-inertial fusion: A Gaussian filtering network approach. *Acta Automatica Sinica*, 2024, **50**(5): 991–1000
(杨旭升, 李福祥, 胡佛, 张文安. 基于肌电惯性融合的人体运动估计: 高斯滤波网络方法. 自动化学报, 2024, **50**(5): 991–1000)
 - 27 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
(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)
 - 28 Yan S, Liang Y, Zheng L, Fan M Y, Wang X X, Wang B L. Explainable gated Bayesian recurrent neural network for non-Markov state estimation. *IEEE Transactions on Signal Processing*, 2024, **72**: 4302–4317
 - 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



杨旭升 浙江工业大学信息工程学院副教授. 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 professor at the College of Information Engineering, Zhejiang University of

Technology. His research interests include information fusion estimation, human motion estimation, and target positioning.)



杨基业 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: yangjiye@zjut.edu.cn
(**YANG Ji-Ye** Master student at the College of Information Engineering, Zhejiang University of Technology. His research interests include human motion

estimation and information fusion estimation.)



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 interests include multi-source information fusion estimation and its applications. Corresponding author of this paper.)