

基于KPCA的膝关节多模式连续运动估计

张建华¹, 王豪¹, 李克祥^{1,2}, 王唱^{1,2}

1. 河北工业大学机械工程学院, 天津 300401; 2. 河北工业大学电工装备可靠性与智能化国家重点实验室, 天津 300401

【摘要】为了实现不同运动模式下膝关节连续运动的有效估计,提出一种基于核主成分分析(KPCA)的下肢膝关节连续运动估计方法。首先,融合多维表面肌电信号时域特征获取不同运动模式下较为全面的运动信息;其次,采用KPCA方法进行肌电特征降维,获取与该类运动模式最为相关的主成分向量,并基于反向传播神经网络实现不同运动模式下膝关节连续运动的有效估计;最后,对5个实验对象的4种运动模式进行实验验证。结果表明该方法不仅可有效估计不同运动模式下膝关节连续运动角度,相对于PCA算法估计精度也有明显提高。

【关键词】表面肌电信号;核主成分分析;时域特征;连续运动估计

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2023)06-0742-08

KPCA-based continuous motion estimation of knee joint in multiple motion modes

ZHANG Jianhua¹, WANG Hao¹, LI Kexiang^{1,2}, WANG Chang^{1,2}

1. School of Mechanical Engineering, Hebei University of Technology, Tianjin 300401, China; 2. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300401, China

Abstract: A kernel principal component analysis (KPCA) based method is proposed for the effective estimation of multi-mode continuous motion of knee joint. The time domain features of multi-dimensional surface electromyography signal are fused to obtain the comprehensive motion information in different motion modes. Then, KPCA method is used to reduce the dimensionality of EMG features and obtain the most relevant principal component vectors, and the effective estimation of multi-mode continuous motion of knee joint is realized through the combination with back propagation neural network. Experimental verification is carried out on 4 motion modes of 5 subjects. The results show that the proposed method can not only effectively estimate the multi-mode continuous motion angles of knee joint, but also significantly improve the estimation accuracy as compared with PCA algorithm.

Keywords: surface electromyography signal; kernel principal component analysis; time domain feature; continuous motion estimation

前言

表面肌电信号(Surface Electromyography Signal, sEMG)直接反映与运动相关联的肌肉生理活动状态,蕴含大量的运动信息,如关节力矩、关节运动量和关节角度等,因此,常作为外骨骼与人之间交互的媒介^[1-2]。由大量的下肢外骨骼机器人研究可

知,不同运动模式下的膝关节连续运动估计对外骨骼运动控制具有重要意义^[3-5]。为应对生活中不同的应用场景,外骨骼需适应不同的运动模式,同时也对机器人的控制精度有着较高的要求^[6-8]。目前针对下肢运动意图识别研究大多聚焦于动作分类和相位识别,而对于膝关节连续运动角度估计的研究相对较少。在基于生物力学模型的关节连续运动估计研究中,Zhao等^[9]通过将sEMG信号与肌肉生理参数结合,建立肌电信号与肌肉骨骼映射模型,实现连续运动变量的估计。但是由于肌肉生理参数难以确定,致使该模型搭建复杂,应用受限^[10-11]。丁其川等^[12]通过采集上肢多关节sEMG信号,提取肌肉活跃度特征,利用主元分析算法处理关节运动特征,并建立高阶多项式映射模型,结果表明该模型的估计效果优于传统方法。熊安斌等^[13]通过采集上肢单通道

【收稿日期】2023-01-04

【基金项目】河北省自然科学基金(F20202051);河北省博士后科研项目(B2022003016);省部共建电工装备可靠性与智能化国家重点实验室人才培养项目(EERIPD2021011);天津市杰出青年科学基金(19JCJC61600)

【作者简介】张建华,博士,教授,研究方向:康复机器人、智能机器人技术、模式识别,E-mail: jhzhang@hebut.edu.cn

【通信作者】李克祥,博士,讲师,研究方向:外骨骼机器人、人体意图识别、人机交互,E-mail: kexiang_lee@163.com

sEMG 信号,提取时域和频域特征,并用主元分析法进行降维处理,最后通过支持向量机分类器识别 5 种手部动作,识别率达 80.4%。雷建超等^[14]通过采集不同性别实验者的 sEMG 信号,利用小波包分解提取特征,并直接导入支持向量机中识别手势动作,结果表明平均识别率达 96%。刘磊等^[15]通过提取 sEMG 信号的小波包特征,利用核主成分分析 (Kernel Principal Component Analysis, KPCA) 进行降维处理,通过相关向量机对上下楼、上下坡和平地行走 5 种模式进行识别,识别率达 96.67%。Wang 等^[16]针对人体膝关节的伸曲、下蹲和行走 3 种模式,提出小波包特征与极限学习机相结合的角度估计方法,可有效估计连续运动的多关节角度。张琴等^[17]通过建立支持向量机与肌电信号的映射模型,对不同速度下的下肢关节进行估计,结果表明在适速行走时该模型对膝和髌关节的运动估计是可行的。王斐等^[18]针对 3 种不同速度的下肢平地行走模式,提取零点和波长等时域特征,利用主成分分析 (Principal Component Analysis, PCA) 进行降维,并建立长短期记忆网络与肌电信号映射模型,结果表明其对髌、膝和踝关节运动的角度估计精度较高。陈天麟等^[19]采集膝关节跨越障碍时的 sEMG 和关节角度信号,然后将均方根特征直接作为反向传播 (Back Propagation, BP) 神经网络估计模型的输入量,结果表明对于人体在跨越障碍时的膝关节角度估计,准确率达 93.3%。综上所述,人体关节连续运动估计对外骨骼机器人的运动控制有着重要的研究价值,但针对下肢连续运动估计的研究较少,且运动模式单一,研究对象多为上下楼梯和上下坡等常见步态。另外,在对 sEMG 信号特征进行分析时,大多直接将原始运动特征导入估计模型中进行识别。肌电特征间存在高冗余性,且 sEMG 信号具有高非线性,直接输入估计模型往往会影响估计的精度,难以保证估计结果的可靠性。

针对以上研究的优势和不足,本研究对平地行走、骑行、上坡和抬腿 4 种运动模式下的膝关节连续运动估计展开研究,提出一种 KPCA 降维融合算法,充分提取肌电特征数据中的非线性信息,并结合 BP 神经网络建立下肢连续运动估计模型。首先,选取 4 种运动模式下的 sEMG 信号作为信息源,提取肌电信号的平均绝对值 (Mean Absolute Value, MAV)、波长 (Wave Length, WL)、均方根 (Root Mean Square, RMS) 和过零点数 (Zero Crossing, ZC) 4 种时域特征;然后,针对肌电特征数据具有非线性和高冗余的特点,利用 KPCA 算法对其进行降维融合处理;最后,将降维融合后的特征向量输入到 BP 神经网络,实现不同运动模式下膝关节角度的有效估计。

1 实验设计与采集

本研究使用 Trigno 无线肌电采集系统 (USA Delsys) 对 sEMG 信号进行采集,该装置可以同时采集 16 个通道的肌电数据,每个通道的采样率设置为 2 000 Hz。采用 BWT901CL 惯性传感器 (Inertial Measurement Unit, IMU) 对关节角度进行测量,设置采样频率为 10 Hz。在实验开始前,对 4 块肌肉皮肤表面及肌电传感器电极表面进行清洁处理,并对 IMU 进行适当校准。当人竖直站立时,膝关节角度为 0°,腿部向前摆动为正方向,向后为负方向。

本研究共选取了 5 位 23~26 岁的实验对象,具体信息见表 1。

表 1 实验对象信息
Table 1 Information of subjects

实验对象	性别	年龄/岁	身高/cm	体质量/kg	健康情况
1	男	25	173	68	健康
2	男	24	173	60	健康
3	男	26	176	72	健康
4	男	23	171	63	健康
5	男	25	178	73	健康

在 4 种运动模式下进行膝关节运动实验时,股直肌、股内侧肌、股二头肌和半腱肌能较好地表征下肢关节的运动状态,且与膝关节运动相关性最大^[20-21]。所以选取以上 4 块肌肉进行 sEMG 信号采集 (图 1)。




图 1 下肢肌肉群分布
Figure 1 Distribution of lower limb muscle groups

在平地行走、上坡、骑行和抬腿这 4 种运动模式下,分别采集每位实验者的肌电信号与膝关节角度信号,每种运动模式采集 3 min,共采集 3 次。为防止肌肉疲劳,每组实验间歇 5 min,运动频率与节拍器保持一致。实验过程如图 2 所示。(1)平地数据采集 (图 2a):实验对象在跑步机上连续行走。跑步机匀速运行,膝关节角度为 -20°~25°,一个运动周期为 3.5 s。(2)

上坡数据采集(图2b):实验对象在坡度为30°的跑步机上连续行走。跑步机匀速运行,膝关节角度为35°~80°,一个运动周期为3.5 s。(3)骑行数据采集(图2c):实验对象在动感单车上连续骑行。骑行阻力为恒定值,膝关节角度范围为-30°~35°,一个运动周期为3.5 s。(4)抬腿数据采集(图2d):实验对象站在平地上做连续的抬腿运动。膝关节角度范围为20°~80°,一个运动周期为3.5 s。



图2 4种运动模式实验采集图

Figure 2 Experimental data acquisition in 4 motion modes

2 sEMG 预处理及特征提取

由于肌电信号采集过程中存在较多的噪声等干扰,原始sEMG信号不能直接用于网络模型的输入。因此,需对sEMG进行预处理和特征提取。

2.1 预处理

实验过程受50 Hz的工业频率、0~20 Hz的电极单元触发频率和电极传感器与皮肤表面贴合不稳定等影响,需要采用30~300 Hz的带通滤波器和50 Hz的陷波滤波器对原始sEMG信号进行滤波处理^[22]。同时为保证肌电信号和膝关节角度信号频率一致,需进行子采样处理^[23]。

2.2 特征提取

sEMG具有强非线性特点,并且是一种非平稳的微弱生理电信号。因此,为较全面获取sEMG信号的有效信息,采用时间窗的方式提取特征值^[24]。窗长度 T 设定为0.20 s,每次平移长度为 b 。为提高数据鲁棒性,防止信息缺失或过度重复,令 $b=T/2$,以确保每次都有一半信号是叠加的。时域特征计算方便、特征直观,已广泛应用于肌电信号研究^[25]。本研究选取MAV、WL、RMS及ZC这4种时域特征进行分析。

MAV体现了在时间窗内信号的整体强度,其值越大,所反映的肌肉激活程度越高。

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (1)$$

其中, x_i 表示每个通道信号第 i 个样本点的幅值, N 为每次特征提取时的滑动窗内采样点数。

WL指在一段时间段内,sEMG信号相邻采样点的幅值累计变化量,反映了数据的幅值变化情况。

$$WL = \frac{1}{N} \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (2)$$

RMS体现了sEMG在一段时间内的有效程度,可反映信号强度与肌肉发力状态变化关系。

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_{i+1}^2} \quad (3)$$

ZC指的是在选取的时间窗内,sEMG幅值通过 x 轴的次数,其值越大,表示信号变化越明显。

$$ZC = \sum_{i=2}^N \text{sgn}(x_i x_{i-1}) \quad (4)$$

$$\text{sgn}(x) = \begin{cases} 1, & x > 0 \\ 0, & x < 0 \end{cases}$$

3 特征降维与估计算法

本研究基于KPCA和BP神经网络建立膝关节连续运动角度估计模型。首先采集4种运动模式下的sEMG信号,基于滑动时间窗提取时域特征;然后,为充分提取sEMG中的非线性信息,利用KPCA降维融合方式处理多源时域特征;最后,将降维融合后的特征向量导入BP神经网络,对膝关节角度进行估计。该模型很好地结合了KPCA的非线性特征提取能力和BP神经网络的非线性映射和回归能力。具体流程见图3。

3.1 基于KPCA的多特征降维融合算法

不同肌肉群之间的sEMG信号存在较强的非线性关系。为更好地获取表征运动特征的非线性信息,本研究采用KPCA进行特征降维融合。KPCA是PCA的核版本,先将特征向量通过事先选取的非线性映射函数映射到高维特征空间中,再使用PCA线性方法计算主元成分。KPCA既保持了PCA的优点,又解决了非线性降维问题。

假设时域特征样本点为 z_j , m 表示特征维数,由原始时域特征向量组成矩阵 X :

$$X = \begin{bmatrix} z_{11} & \cdots & z_{1m} \\ \vdots & \ddots & \vdots \\ z_{j1} & \cdots & z_{jm} \end{bmatrix} = [z_1 \quad \cdots \quad z_m] \quad (5)$$

其中, j 表示特征值样本点数。

通过非线性映射 Φ 将 X 中的输入样本映射到高维特征空间 F 中,可得 F 的样本数据协方差矩阵 C :

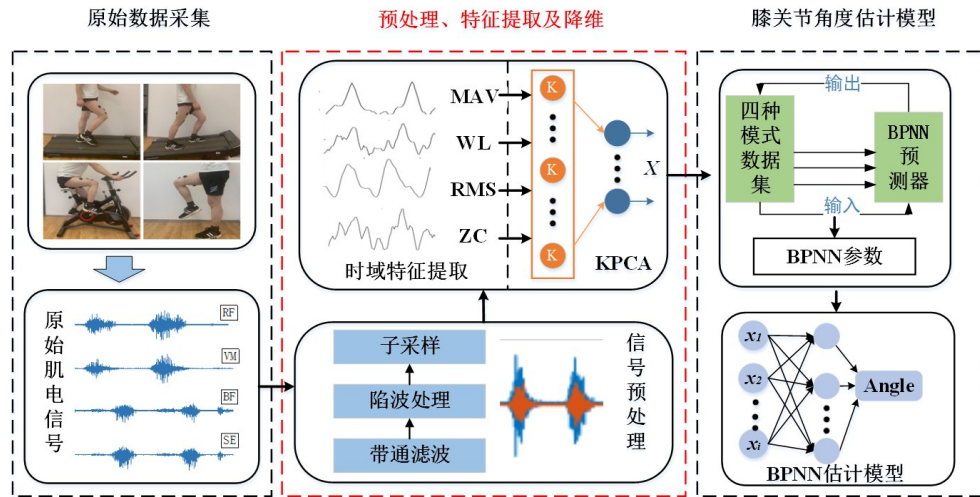


图3 连续运动膝关节角度估计流程

Figure 3 Flowchart of continuous motion angle estimation of knee joint

$$C = \frac{1}{m} \sum_{j=1}^m \phi(z_j) \phi(z_j)^T \quad (6)$$

通过迭代法计算特征值 λ 和特征向量 ω ,特征向量由式(7)表示:

$$\omega = \sum_{j=1}^m \alpha_j \phi(z_j) \quad (7)$$

其中, α_j 为方程系数。

特征值与特征向量的关系,可由式(8)表示:

$$C\omega = \lambda\omega \quad (8)$$

通过式(6)~式(8)计算,且两边与 $\phi(z_j)^T$ 做内积得:

$$\frac{1}{m} \phi(z_j) \phi(z_j)^T \sum_{j=1}^m \alpha_j \phi(z_j) \phi(z_j)^T = \lambda \sum_{j=1}^m \alpha_j \phi(z_j) \phi(z_j)^T \quad (9)$$

在高维空间中,直接求解 $\phi(z_j) \phi(z_j)^T$ 较为困难,通常引入核函数进行处理。本研究使用径向基核函数进行计算,定义一个 $m \times m$ 的矩阵,表达式为:

$$K = \phi(z_j) \phi(z_j)^T \quad (10)$$

通过式(11)对矩阵 K 的特征值 λ 与特征向量 α 进行求解:

$$m\lambda\alpha = K\alpha \quad (11)$$

核矩阵 K 的特征值为 $m\lambda$,对应的特征向量为 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_m)$,经施密特正交化和单位化处理得到新主元成分向量 $\gamma = (\gamma_1, \gamma_2, \gamma_k, \dots, \gamma_m)$ 。当前 K 个主元成分的累计贡献率大于阈值时,选取 $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_k)$ 作为降维融合后的数据。

3.2 基于BP神经网络估计算法

本研究通过构建3层BP神经网络来实现sEMG到膝关节角度的映射。将实际测量结果作为真实值进行网络训练。输入层神经元个数由输入特征量的维度决定;输出层有1个神经元,为膝关节的角度估

计值。选择合适的隐藏层神经元数目是网络训练的重要因素,过大可能导致训练周期长、效率低和过拟合;过小可能造成学习效果不好、欠拟合和误差较大,因此可根据式(12)对其进行计算:

$$L = \sqrt{n + m} + a \quad (12)$$

其中, L 为隐藏层神经元个数, n 为输入层神经元个数, m 为输出层神经元个数, a 为 $[1, 10]$ 之间的常数。当 $n = 4$ 且 $m = 1$ 时,隐藏层神经元个数在 $[4, 13]$ 之间最为适宜。以节点数为控制变量进行实验比较,结果如图4所示。随着节点数的增加,4种运动模式下的均方根误差(Root Mean Square Error, RMSE)均有所降低;但是当节点数目超过12之后, RMSE开始增加,这是由于节点数过低或过大时,网络模型出现训练突然中止不稳定情况或过拟合的现象造成的。经综合衡量后,选定隐藏层神经元个数为12。




图4 不同隐藏层节点比较

Figure 4 Comparison of different hidden layer nodes

4 实验结果与分析

为实现对不同运动模式下膝关节连续运动角度的准确估计,将同一动作下的每位实验者样本数据按照8:2的比例分割,分别作为训练集和测试集。另外,采用 RMSE 和皮尔森相关系数 (Pearson's Coefficient, ρ) 作为估计结果的评价指标。

RMSE 表示真实值和估计值之间差值的平方和与样本数比值的平方根,其值越小表明估计结果较好。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum (\theta_p - \theta_r)^2} \quad (13)$$

其中, θ_p 表示膝关节估计角度, θ_r 表示膝关节实际角

度, n 表示样本点数。

ρ 用来衡量估计结果与实际膝关节角度相似度的强弱,数值范围在区间(0, 1)内,结果越接近1表示两变量的相似程度越高。

$$\rho = \frac{\text{Cov}(\theta_p, \theta_r)}{\sigma_p \sigma_r} \quad (14)$$

其中, σ_p 和 σ_r 分别为估计和实际角度的标准差。

图5为4种运动模式下的4个通道的原始 sEMG 信号。以下肢股直肌通道为例,提取 MAV、WL、RMS 和 ZC 这4种时域特征(图6)。从图中可以看出,时域特征能较好地表征原始 sEMG 信号随时间变化的趋势。

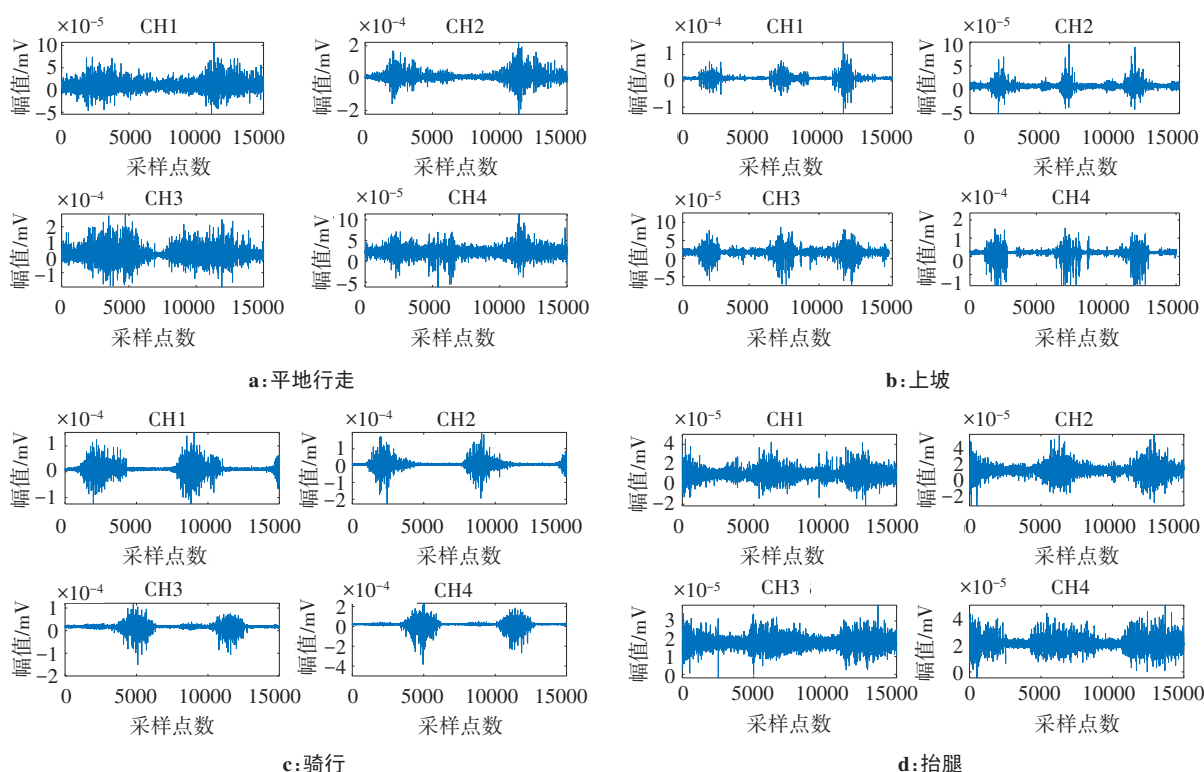


图5 原始sEMG肌电信号

Figure 5 Original sEMG signals

本实验经过KPCA计算得到10个主成分PC(1~10),见表2。其中,PC1的贡献率所占比例远大于其他主成分的贡献率所占比例,且第4~10个主成分贡献率所占比例逐渐稳定。按照累计贡献率92.5%为阈值,选择前4个主成分代替原始特征向量,能充分表征下肢运动特征,因此选取 $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_4)$ 作为估计模型的输入。

首先,对实验者的每块肌肉,均提取1种时域特征,组成4维的单一时域特征向量导入角度估计模型,估计结果如图7所示。整体RMSE在17°~22°之

间,在4种运动模式中,均方根时域特征的估计精度均优于其他时域特征,但是整体RMSE较大,表明单个特征不能充分表征运动信息。因此为了更充分地表征膝关节运动特征信息,需要提取 sEMG 信号的多个时域特征,进而实现连续运动模式下膝关节的角度精准估计。

之后,对实验者的每块肌肉,均提取4种时域特征,组成16维的时域特征向量,称为多时域特征向量 (Multiple Time Domain Eigenvectors, MTDE)。因原始 MTDE 具有较强的非线性关系及高冗余性,故需




图6 股直肌sEMG信号的时域特征

Figure 6 Time domain features of sEMG signal of rectus femoris

表2 主成分的累积贡献率(%)

Table 2 Cumulative contribution rates of principal components (%)

KPCA 主成分	累计贡献率H
PC1	70.5
PC2	85.5
PC3	90.6
PC4	92.5
PC5	93.1
PC6	94.2
PC7	95.6
PC8	97.3
PC9	97.8
PC10	98.1

对其进行降维融合处理。为了验证提出的KPCA降维融合方法在精度和稳定性方面的优势,与传统PCA降维方法进行比较,分别将原始MTDE以及经PCA和KPCA降维融合后的特征向量作为估计模型输入量,求其RMSE和标准差(Standard Deviation, SD),结果如表3所示。




图7 单一特征下的RMSE比较

Figure 7 Comparison of root mean square error of a single feature

表3 不同方法下的角度估计标准差(°)

Table 3 Standard deviation of angle estimation using different methods (°)

运动模式	MTDE-BP		PCA-BP		KPCA-BP	
	SD	RMSE	SD	RMSE	SD	RMSE
平地行走	0.854	20.54	0.799	14.54	0.787	10.82
上坡	0.856	19.54	0.821	13.50	0.679	9.81
骑行	0.789	18.11	0.778	11.98	0.556	9.61
抬腿	0.868	23.58	0.849	15.68	0.804	11.65

原始MTDE作为估计模型输入量时的标准差和RMSE最大,说明直接利用MTDE不能准确稳定地估计膝关节角度值。PCA虽然对时域特征进行降维融合,但对膝关节角度的估计精度提升有限,表明未充分提取到表征运动信息的特征。通过KPCA降维融合之后,估计精度明显优于使用原始MTDE估计的结果,具有更好的稳定性;而与PCA降维融合之后的估计结果相比,估计精度和稳定性也得到进一步提升。通过计算,相较于原始MTDE、PCA降维融合方法,KPCA-BP在4种运动模式下整体平均RMSE降低46.94%~50.59%和19.78%~27.33%。上述对比分析表明,使用KPCA可有效地提取肌电信号的非线性信息,且降低特征的维数。

为了更直观地表现KPCA降维融合后的估计效果,本研究对4种运动模式下膝关节连续运动角度估计的曲线图和相关性图进行分析(图8和图9)。由角度估计曲线图可知,4种运动模式下的角度估计曲线整体较为平滑,更接近真实值,但是在曲线拐点处的角度估计误差较大,这是由于在膝关节角度达到最值时,对应4种运动模式中膝关节运动到极限处的位置,此时膝关节易晃动,导致sEMG信号采集不充分,所以估计误差也相对较大。4种运动模式的角度估计相关性约为90%,表明角度估计结果与实际膝关节

角度整体上较为接近。综上所述,本研究所提的KPCA-BP神经网络估计模型可有效估计不同运动模式下膝关节连续运动角度。

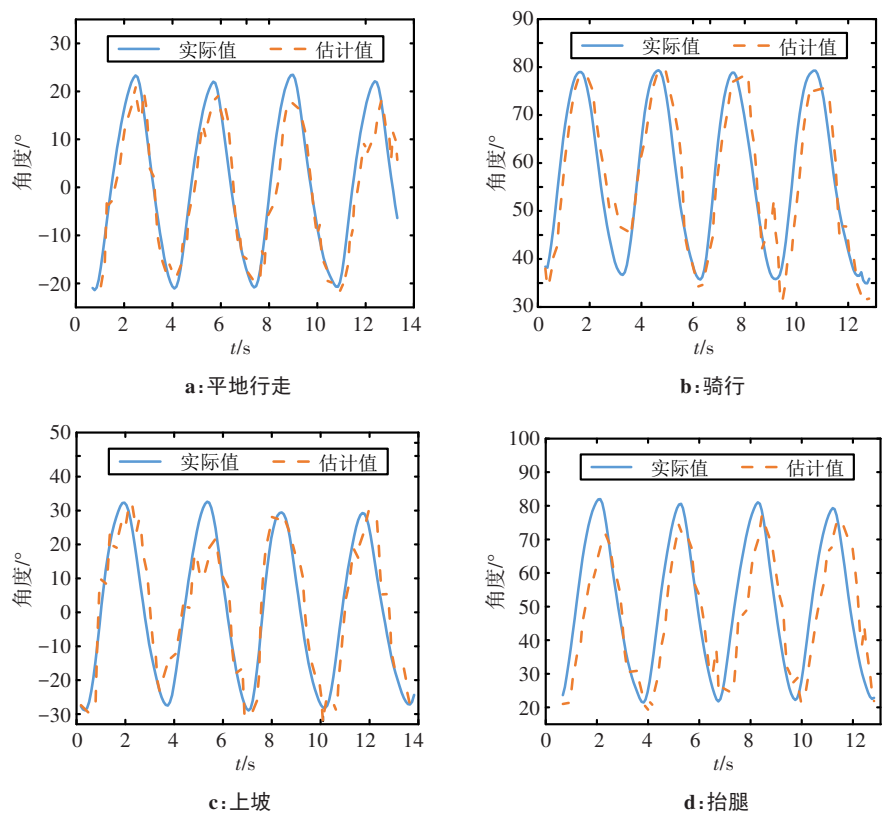


图8 膝关节连续运动角度估计曲线图
Figure 8 Continuous motion angle estimation of knee joint




图9 角度估计的相关性图和相关系数
Figure 9 Correlation plot and correlation coefficient for angle estimation

5 结 论

本研究针对不同运动模式下膝关节连续运动角度估计问题,提出一种将KPCA和BP神经网络相结合的估计模型。利用KPCA算法对肌电时域特征进行降维融合处理,并与原始MTDE、PCA降维融合方法比较。实验结果表明,相较于原始MTDE、PCA降维融合方法,KPCA-BP在4种运动模式下整体平均RMSE降低46.94%~50.59%和19.78%~27.33%,稳定性也有所提高,说明KPCA算法可以有效地提取肌电信息中的非线性特征,并去除特征冗余性。未来工作中,该模型可与外骨骼机器人、康复机器人等结合,增强机器人与人体运动的匹配性,对于下肢外骨骼人机交互研究有重要应用价值。

【参考文献】

- [1] Yao J, Guo N, Xiao Y, et al. Lower limb joint motion and muscle force in treadmill and over-ground exercise[J]. Biomed Eng Online, 2019, 18(1): 1-12.
- [2] Sun Y, Xu C, Li G, et al. Intelligent human computer interaction based on nonredundant EMG signal[J]. Alex Eng J, 2020, 59(3): 1149-1157.
- [3] Yan Y, Chen Z, Huang C, et al. Human-exoskeleton coupling dynamics in the swing of lower limb[J]. Appl Math Model, 2022, 104: 439-454.
- [4] Li KX, Zhang JH, Wang LF, et al. A review of the key technologies for sEMG-based human-robot interaction systems [J]. Biomed Signal Proc Control, 2020, 62(102074): 1-17.
- [5] Kiguchi K, Hayashi Y. An EMG-based control for an upper-limb power-assist exoskeleton robot[J]. IEEE Trans Syst Man Cybern B Cybern, 2012, 42(4): 1064-1071.
- [6] Tran P, Jeong S, Herrin KR, et al. A review: hand exoskeleton systems, clinical rehabilitation practices, and future prospects[J]. IEEE Trans Med Robotics Bionics, 2021, 3(3): 606-622.
- [7] Chen JC, Zhang XD, Cheng Y, et al. Surface EMG based continuous estimation of human lower limb joint angles by using deep belief networks[J]. Biomed Signal Proces Control, 2018, 40: 335-342.
- [8] Shi D, Zhang W, Zhang W, et al. A review on lower limb rehabilitation exoskeleton robots[J]. Chinese Journal of Mechanical Engineering, 2019, 32(1): 1-11.
- [9] Zhao Y, Zhang Z, Li Z, et al. An EMG-driven musculoskeletal model for estimating continuous wrist motion[J]. IEEE Trans Neural Syst Rehabil Eng, 2020, 28(12): 3113-3120.
- [10] Han JD, Ding QC, Xiong AB, et al. A state-space EMG model for the estimation of continuous joint movements [J]. IEEE Trans Ind Electron, 2015, 62(7): 4267-4275.
- [11] Li KX, Zhang JH, Liu X, et al. Estimation of continuous elbow joint movement based on human physiological structure[J]. Biomed Eng Online, 2019, 18(1): 31.
- [12] 丁其川, 赵新刚, 韩建达. 基于肌电信号的上肢多关节连续运动估计[J]. 机器人, 2014, 36(4): 469-476.
- [13] Ding QC, Zhao XG, Han JD. Continuous motion estimation of multiple joints of upper limb based on EMG signal [J]. Robot, 2014, 36(4): 469-476.
- [14] 熊安斌, 丁其川, 赵新刚, 等. 基于单通道sEMG分解的手部动作识别方法[J]. 机械工程学报, 2016, 52(7): 6-13.
- [15] Xiong AB, Ding QC, Zhao XG, et al. Hand motion recognition method based on single channel sEMG decomposition [J]. Journal of Mechanical Engineering, 2016, 52(7): 6-13.
- [16] 雷建超, 刘栋博, 房玉, 等. 基于表面肌电信号的性别差异性手势识别[J]. 中国医学物理学杂志, 2020, 37(3): 337-341.
- [17] Lei JC, Liu DB, Fang Y, et al. Gender difference gesture recognition based on sEMG[J]. Chinese Journal of Medical Physics, 2020, 37(3): 337-341.
- [18] 刘磊, 杨鹏, 刘作军, 等. 采用核主成分分析和相关向量机的人体运动意图识别[J]. 机器人, 2017, 39(5): 661-669.
- [19] Liu L, Yang P, Liu ZJ, et al. Human motion intention recognition using kernel principal component analysis and correlation vector machine [J]. Robot, 2017, 39(5): 661-669.
- [20] Wang JH, Wang L, Xi XG, et al. Estimation and correlation analysis of lower limb joint angles based on surface electromyography [J]. Electronics, 2020, 9(4): 556.
- [21] 张琴, 骆无意, 黄波, 等. 基于肌电信号的下肢关节连续运动预测[J]. 华中科技大学学报(自然科学版), 2017, 45(10): 128-132.
- [22] Zhang Q, Luo WY, Huang B, et al. Continuous motion prediction of lower limb joints based on EMG signals[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2017, 45(10): 128-132.
- [23] 王斐, 魏晓童, 秦峰. 基于sEMG和LSTM的下肢连续运动估计[J]. 东北大学学报(自然科学版), 2020, 41(3): 305-310.
- [24] Wang F, Wei XT, Qin H. Lower limb continuous motion estimation based on sEMG and LSTM [J]. Journal of Northeast University (Natural Science Edition), 2020, 41(3): 305-310.
- [25] 陈天麟, 戴俭民, 程光, 等. 基于肌电信号的膝关节跨越障碍角度预测方法[J]. 中国医学物理学杂志, 2020, 37(10): 1293-1301.
- [26] Chen TL, Dai QM, Cheng G, et al. Prediction method of knee crossing obstacle angle based on EMG signal[J]. Chinese Journal of Medical Physics, 2020, 37(10): 1293-1301.
- [27] Wang J, Wang L, Miran SM, et al. Surface electromyography based estimation of knee joint angle by using correlation dimension of wavelet coefficient[J]. IEEE Access, 2019, 7: 60522-60531.
- [28] Lessi GC, Santos AF, Batista LF, et al. Effects of fatigue on lower limb, pelvis and trunk kinematics and muscle activation: gender differences [J]. J Electromyogr Kines, 2017, 32: 9-14.
- [29] 刘建, 邹任玲, 张东衡, 等. sEMG特征提取方法研究发展趋势[J]. 生物医学工程学进展, 2015, 3: 164-168.
- [30] Liu J, Zou RL, Zhang DH, et al. Research and development trend of sEMG feature extraction methods [J]. Progress of Biomedical Engineering, 2015, 3: 164-168.
- [31] Zhang F, Li PF, Hou ZG, et al. sEMG-based continuous estimation of joint angles of human legs by using BP neural network [J]. Neurocomputing, 2011, 78(1): 139-148.
- [32] Bi L, Guan C. A review on EMG-based motor intention prediction of continuous human upper limb motion for human-robot collaboration [J]. Biomed Signal Process Control, 2019, 51: 113-127.
- [33] Phinyomark A, Phukpattaranont P. Feature reduction and selection for EMG signal classification[J]. Expert Syst Appl, 2012, 39(8): 7420-7431.

(编辑:谭斯允)