

基于筋骨假人和意图标注的躯干肌电预测结果校正

王琦 周志勇

(上海电机学院设计与艺术学院 上海 200240)

摘要 在人机交互领域,预测躯干肌电信号极具应用潜力。但手部操作、平衡条件等因素会导致躯干肌肉控制模式转换,破坏躯干基于运动信号和肌电信号间的映射关系,因此很难实现高精度躯干肌电预测。为实现对应意图的躯干肌电预测,在设定弯伸腰任务内,测量一组部分椎旁肌肌电信号及运动信号,通过对多维椎旁肌肌电信号的多次两步聚类编码,将其转化为聚类编码号组成的动作向量,作为 BiLSTM-CRF 算法的输入,实现躯干肌肉动作的分时段标注,进而利用筋骨假人分别校正躯干肌电预测结果。预测校正结果可反映个体特征、躯干和手部动作意图。

关键词 椎旁肌 动作意图 两步聚类 双向长短时神经网络 肌电

中图分类号 TP391.77

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.08.014

CALIBRATION OF PREDICTION RESULTS OF TRUNK EMG BASED ON MUSCULOSKELETAL MANNEQUIN AND INTENTION LABELING

Wang Qi Zhou Zhiyong

(School of Industrial Design, Shanghai Dianji University, Shanghai 200240, China)

Abstract Prediction of trunk muscle electromyography (EMG) has great application potential in the field of man-machine interaction. However, the control modes of the trunk muscles alternate with human intentions, hand operations, balance conditions and other factors, which undermines the mapping relationship between motion signals and EMG signals. Therefore, it is difficult to realize the high-precision prediction of the trunk EMG. In order to achieve EMG prediction corresponding to the intentions, the EMG signals of a group of paravertebral muscles and motion signals were measured during preset flexion-extension tasks. The multi-dimensional EMG signals of paravertebral muscles were transformed into action vectors composed of Two-step Clustering numbers. The action vectors were used as the input of BiLSTM-CRF algorithm to realize the tagging of trunk muscle actions during different periods, and the musculoskeletal mannequin was used to calibrate the trunk EMG prediction results. The calibration results can reflect the intention of the trunk, the hands and the individual characteristics.

Keywords Paravertebral muscles Action intention Two-step clustering Bidirectional long and short-term neural network Electromyography

0 引言

躯干肌肉行为能反映姿态控制、平衡控制、紧张感、阻尼感、病痛等多类信息。在使用假肢、外骨骼等交互场景下,有极大应用潜力^[1-3]。在模拟驾驶、滑雪、冲浪等场景时,预测、识别躯干肌肉的协同行为,对

于交互界面的仿真效果至关重要,往往直接决定了交互体验^[4-5]。在设计人体康复辅助设备时,监测躯干肌肉状态,并调节互动过程,令行为符合主观预期也很重要^[6]。然而,当前对自身平衡感、位置感、紧张感等信息的提取研究,多以脑电为数据源,而对动作分类研究多以四肢肌肉为数据源^[7-8]。躯干肌电信号识别主要被用于腰痛、帕金森症等疾病的研究,很少被用作控

制信号来源^[9],主要原因如下:

首先,躯干肌电信号难以直接用于动作分类,其应用场景不如四肢直观^[10]。其次,逆向动力学计算模型和深度学习算法,都需要肌电信号与运动输出间存在映射关系。而躯干的控制方式不唯一,肌电信号与运动信号间的映射关系被破坏。基于运动信号预测肌电信号,或者基于运动信号进行分类,都缺少应用深度学习算法进行预测的必要条件。当前 ANYBODY 等人体有限元分析软件可以模拟不同人体控制模式下的肌肉、骨骼、韧带的力学状态,但无法获知具体动作任务下频繁变化的动作控制意图选择。

为克服以上问题,实现高精度躯干肌电预测,一种可能的方式是利用命名实体识别算法,建立躯干肌电信号编码构建输入向量,进而标注躯干肌电反映出的体内外行为协作意图。在不同动作意图时段内预测肌电信号。

研究目的是划分躯干肌电信号组,提取行为的排列规则,且予以标注,进而逐时段选用发力方式近似的 ANYBODY 假人模型,校正躯干肌肉的激活状态预测。理论上,这种方法可以充分利用肌肉行为的时序信息和个体特征,并从长时间信号中记忆特定肌肉行为,高精度预测躯干肌肉激活程度和其他人体组织的力学状态,这是当前基于人工神经网络算法和动作分类方法的预测方法无法实现的。

1 实验

1.1 实验设计

设计了伴有右手持物操作的弯伸腰实验步骤,以测量能反映姿态控制、平衡条件、手操作等因素的训练数据和验证数据,用于 BILSTM-CRF 算法标注。所测数据也为基于 ANYBODY 假人的预测提供运动信号,作为输入信号。

自变量包括手持物的重量、腿姿态,以及左手是否有支撑。共 26 种自变量设置组合方式。每种重复 3 次。由 11 名男性实验对象先完成最大自主收缩(MVC)测量步骤,再测量实验对象基本数据和臂长,臂长表示为肩峰到近侧指间关节(PIP)的长度。3 个手操作目标位置设置在右手一侧,在人体前后方向位置随臂长调整,保证各实验对象平衡条件一致。

实验对象依照随机实验表,完成自变量设定不同的 26 类弯伸腰伸手动作循环,每类 3 次。每次用右手从脚中线右侧 45 cm 远、120 cm 高的架子上拿取砝码,之后垂直向下触碰 80 cm 和 37 cm 目标,再向上返回

80 cm 处和 120 cm 起始处。

1.2 肌电信号选择

先利用 ANYBODY(2.5)提供的有限元模型,根据弯伸动作输出躯干各肌肉在给定动作中的发力曲线,确认肌肉角色,选择与实验任务相关度高的躯干肌肉为信号源。该软件可以把肌束和筋膜细分并简化为二向力学模型,根据逆向动力学算法模拟非对称弯腰动作时的所有肌肉状态。

根据预测结果发现的,与弯伸动作关联度较高的躯干肌肉中,多数无法使用。因脂肪层伸缩,排除了大部分腹部肌肉。因伦理原因,放弃了不易测量的腹部各肌肉和腰大肌。选择了与弯伸动作关联度最高,位置易测量的对侧腰最长肌、髂肋肌。

该假人可以较为准确地分别模拟拮抗状态和弯腰放松状态下的躯干肌肉发力曲线,也能模拟处于二者中间过渡状态的发力曲线。但该模型基于逆向动力学建立,在预判躯干肌肉的发力方式时,无法获知躯干发力模式的选择。不能提取躯干肌肉的行为意图,就难以进一步提高预测精度。

1.3 信号采集

由 8 台高速摄影机对实验对象身上的 23 个反光点进行运动数据采集。同时进行 5 通道表面肌电信号采集。腰部最长肌肌束测量位置在 L1 棘突位置中线的外侧 3 cm 处,电极贴片方向与肌束走向相同。测量髂肋肌的电极处于距 L3 棘突外侧 6 cm 处,方向平行于髂后上棘突与第 12 肋骨外侧缘的连线。采集过程中的贴反光点、电极片、姿势定义如图 1 所示。



图 1 实验中的反光点和电极贴法

对运动信号和肌电信号进行实时监测和初步处理后,两类数据的 C3D 格式数据导入 KineAnalyser (V6.5),完成肌电信号基线补偿、系统延时补偿。输入测好的最大自主收缩值,完成对肌电信号的归一化处理。高低通设定为 30 ~ 500 Hz。

比起通用的反光点选取方式,实验设定中主要增加了用于定义脊椎弯角的 9 号点,处于颈椎 C7 和骶骨 S1 之间体表连线的中点。用所有反光点运动轨迹,驱动 KineAnalyser 提供的骨骼假人。

对比了均方根(RMS)、均值、快速傅里叶变换均值(FFT-mean)等多类时域和频域数据特征,选择在两步聚类步骤中精度最高的快速傅里叶变换中位值(FFT-Median)来表征肌肉活动。窗口时长为 256 ms。

1.4 运动信号定义

为了减少身高体重等参数差异引起的误差,选取躯干角度信号和右手腕位置信号进行姿态描述。KineAnalyser 骨骼假人的反光点位置如图 2 所示。




图 2 骨骼假人的躯干反光点

利用图 2 中的反光点自定义骨骼假人角度信号,所建人体角度信号如表 1 所示。

表 1 角度信号定义

向量	角 1	角 2	角 3	角 4
向量 1	2→9	4→3	4→3	9→10
向量 2	9→10	2→10	3→2	10→16

在后续步骤确认躯干肌肉的协作方式,并据此划分行为后,运动信号被用于驱动 ANYBODY 筋骨假人。

测量结果表明,过程由弯腰放松现象主导。椎旁肌肌电曲线接近“U”形。每当手进行精确操作时,身体控制造成躯干肌肉的短时拮抗状态,表现为瞬时峰值。

2 有限元模拟

利用 ANYBODY 软件可以较准确模拟躯干所处的两种极端情况。其中,完全受拮抗现象支配的情况下,躯干肌肉激活状态曲线称为第一类预测曲线。模拟结果符合逆向动力学平衡方程。对这种状态弯伸过程的模拟方式是图 2 中骨骼假人的反光点坐标用于定义筋骨假人在单次弯伸过程中的 16 个静态平衡状态,再分别计算各静态平衡状态下的肌肉激活状态。实验对象开始到最低点时的 9 帧姿态如图 3 所示,从低点起

身的 9 帧步骤如图 4 所示。




图 3 弯腰步骤

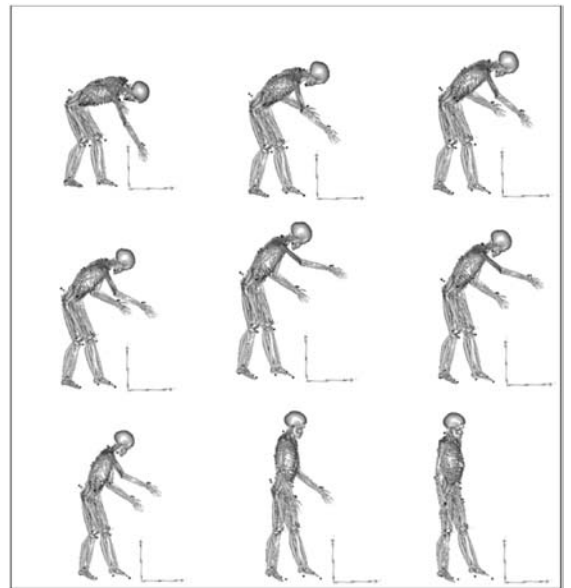


图 4 伸腰步骤

第二类有限元分析模拟的是连续的弯伸腰过程。此时 ANYBODY 软件能模拟弯腰放松现象,弯伸腰力矩被转移给被动组织来平衡。躯干弯角大时肌肉发力反而减小。但该现象会被手操作和平衡扰动引起的拮抗现象打断,表现为瞬时峰值。

把采样略降低至 0.1 次/秒,对比各肌电实测结果与两类预测结果的秩相关性,用 Spearman 相关系数表示,结果如表 2 所示。

表 2 实验对象实测结果与两类预测结果的对比

实验对象	年龄	第一类曲线	第二类曲线
L-IL-S	Correlation Coefficient	.738 (*)	-.731 (*)
	Sig. (2-tailed)	0.037	0.04
R-IL-S	Correlation Coefficient	0.571	-.868 (**)
	Sig. (2-tailed)	0.139	0.005

续表 2

实验对象	年龄	第一类曲线	第二类曲线
L-Lo-S	Correlation Coefficient	0.381	-.731(*)
	Sig. (2-tailed)	0.352	0.04
R-LO-S	Correlation Coefficient	0.333	-.854(**)
	Sig. (2-tailed)	0.42	0.007
I-IL-US	Correlation Coefficient	.762(*)	-0.647
	Sig. (2-tailed)	0.028	0.083
R-IL-US	Correlation Coefficient	0.571	-.868(**)
	Sig. (2-tailed)	0.139	0.005
L-LO-US	Correlation Coefficient	0.238	-0.647
	Sig. (2-tailed)	0.57	0.083
R-LO-US	Correlation Coefficient	0.452	-.790(*)
	Sig. (2-tailed)	0.26	0.02

表 1 中,R 为右侧,IL 指髂肋肌,LO 指最长肌,S 为左手有支撑,US 为左手无支撑状态。

以单个实验对象两侧髂肋肌为例,测量曲线和预测曲线预测结果如图 5、图 6 所示。




图 5 左侧预测和实测结果




图 6 右侧预测和实测结果

可见,总的来说各肌肉的肌电曲线多与第二类预测接近,但在手操作时段接近第一类。可见弯腰放松

现象占主导,而手操作引起了拮抗状态。

3 标注

该算法具有如下关键优势:增加聚类数后,细分过的类的边界点完全覆盖粗分的类的边界。就是说单个粗聚类完全由细聚类组成,调节聚类细分程度时,各聚类结果间不交叉。以聚类号代替原始肌电信号,客观上解决了不同实验对象间的数据对比问题,对比不同实验对象的动作时,不用担心时间轴不同。此外,两步聚类的细分程度便于预设和调节。

考虑到躯干的运动输出都是由多个肌肉协作实现的。其行为规律的提取需要纳入多个不同肌肉。以 4 处椎旁肌肌电信号为输入,利用两步聚类算法输出一维的聚类结果^[11]。每个聚类号对应于这些椎旁肌肌电信号的特定协作方式。在最小聚类分组数设为 3 时获得粗聚类号。逐步增大最小聚类分组数设定,作为细聚类号。单个粗聚类号代表的时段由细分聚类号组成。每种自变量设定下的 3 次弯伸聚类结果如图 7 所示。聚类结果及边界可反映实际动作变化特点。




图 7 聚类数设定对划分结果的影响

由图 7 可见,粗分聚类号表述为细分聚类号者组成的向量。这样的向量被作为长短时神经网络 (Bi-directional Long Short-term Memory Networks, BiLSTM) 的输入,用 V_i 表示。各粗聚类向量对应于如下类别标签:开始 (V_{FS})、弯腰 (V_{FP})、手操作 (V_M)、伸腰 (V_{EP})、恢复直立 (V_{EE}),以及平静状态 (V_N)。平静状态用分组号“N”表示,避免了对无关信号的过度关注。连续的一组动作向量 V_i 构成行为。

行为的标签数据组织形式为 N-S-F-M-E-N。先设定识别标签类型,包括弯腰开始 (FS)、弯腰过渡 (FP)、手操作 (M)、伸腰过渡 (EP)、伸腰结束再平衡 (EE),以及平静状态 (N)。其中 (EE) 只能在 (N) 前。(EE) 在 (EP) 前,(EP) 在 (FP) 前。

采用 Python3.7 + Tensor1.15,为了利用 TensorFlow

处理批量的聚类号,将动作向量填充到相同的长度。取每种自变量设置下的 3 次弯伸循环测量中的前 2 次数据作为训练集。余下的作为测试数据测试集。聚类号组成动作向量,动作组成行为。依次输入训练数据方式如图 8 所示。




图 8 输入数据方式

BiLSTM-CRF 标注过程如图 9 所示。

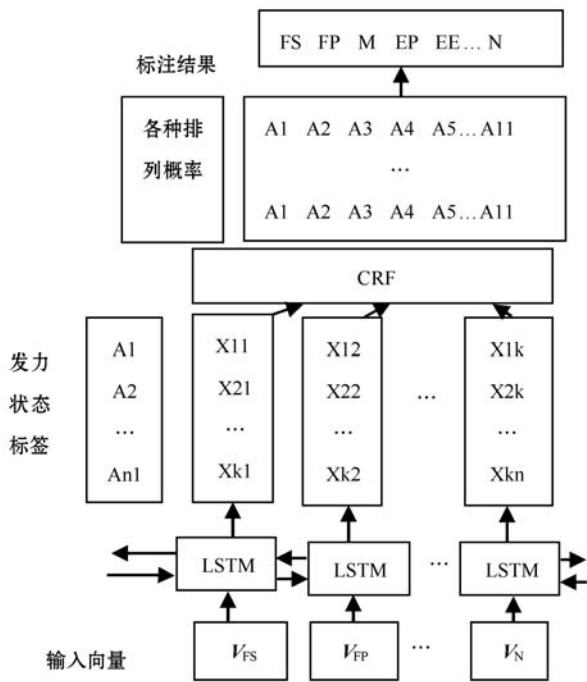


图 9 BiLSTM-CRF 标注流程

为了更好地优化算法,通过多次实验优化参数,各参数设置如下:批处理文件数(batch)为 11,隐藏单元数为 50,学习率设为 0.01,丢弃率(Dropout)设为 0.5。

两步聚类的细分聚类最小分组号为 8 的情况下, Precision 的均值为 87.31%, Recall 的均值 90.16%。以二者的调和平均数 F1 作为评价指标,算术平均值为 88.71%。

4 肌电信号预测校正

ANYBODY 软件提供的肌肉行为模拟结果是渐变的。在快速低负载的弯伸腰情况下,其筋骨假人模拟的是弯腰放松状态。反之,在低速或重载情况下,模拟的是拮抗状态。处于不同档速度的假人在各意图时段

内的椎旁肌发力曲线逐渐由“n”形转为“U”形。但假人不能识别失衡、姿态精确控制等影响肌肉控制模式转换的因素。可以通过调整筋骨假人的弯伸腰速度,来选择肌肉发力的控制方式,在各时段内,根据预测曲线相似度选择假人运动速度,实现校正。

为了选择发力方式合理的假人,在各意图时段内,对比实测肌电信号与 5 种速度下肌肉活动预测曲线的相关性。从静止开始逐渐增躯干弯角的角速度设置,从 0 逐次增加至实际速度的 0.25 倍、0.5 倍、0.75 倍、1 倍和 1.25 倍,共 6 个档位。动作过程中的假人运动路径与实测的运动仍然一致。相关性最好的假人状态在该意图时段内被选用,输出各肌电预测曲线。更多的假人速度预设,还可能实现更高的预测校正精度。

计算预测曲线与实测曲线相关性。双尾显著性值小于 0.05 时,则可认为已确认了发力模式。 ρ 值低于 0.70,说明控制方式不确定。在各时段内,选择与训练集内的同行为实测曲线相关系数最高的预测曲线,代替各时段内原假人预测结果。聚类分组数为 7 的预设下,校正后部分肌肉的预测和实测结果如图 10、图 11 所示。




图 10 右最长肌实测和预测对比




图 11 左髂肋肌实测和预测对比

可见,预测与实测曲线的绝对值差异显著。为了减少各段绝对值差异,在各聚类时段内,根据训练集的肌肉激活程度数据,对肌电信号进行了极差归一化处理,结果如图 12、图 13 所示。




图 12 左最长肌肌电实测和预测对比

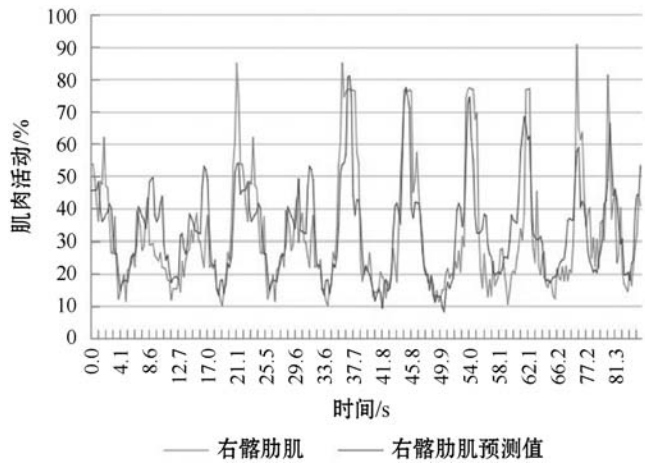


图 13 右锯齿肌实测结果和分时段预测结果的对比

可见,在预测集和训练集由同人完成的条件下,根据意图分类结果,校正后的预测曲线能更准确的对应突发的拮抗或者放松状态,显著提高预测精度。但在手操作引起的拮抗峰值时段,绝对值差异仍存在。

5 校正效果验证

预测校正对象不仅可以是肌肉、也可以是韧带、骨骼,相当于根据一组椎旁肌行为预测所有躯干人体组织的力学状态。但多数内部躯干组织的实测结果不易实测。

预测校正效果验证步骤是在改变平衡条件,也就是改变躯干肌肉控制方式后进行的。选择对右侧持物行为敏感的右斜方肌。对比肌电信号与校正后的预测结果,达到验证校正效果的目的。

以下数据预测的是,在左手有外加支撑情况下,空右手连续精确触碰 120 cm、80 cm、37 cm、80 cm、

120 cm 目标时的部分躯干肌肉发力状态。这种支撑是处于身体边缘外侧的,起不到支撑作用,但用左手触碰时,会改变人对平衡条件的主观预期。

单次弯伸循环内,未经校正的预测结果如图 14 所示。




图 14 未经校正的各肌肉发力百分比

由于校正过程是在各聚类时段内进行的,聚类分组号设定越大,细分程度越高,理论上预测结果更精细,能反映更多个体特征。而预设最小聚类分组数为 3 时的各被侧肌肉结果的预测曲线如图 15 所示。此分组设定下,各实验对象的聚类划分结果在有体型、种族和自变量差异的情况下,保持高度一致。因此不同实验对象的相同聚类号所代表的意图信息互相对应,可彼此对比。




图 15 最小聚类分组数为 3 时的预测校正结果

预测校正结果很好地反映了表现为图 14 中 0.3 秒处的拮抗现象,这是左手扶物引起的心理预期带来的特有加速现象。说明支撑条件没有提供更多的弯腰放松过程,反而导致了更高的主观发力倾向。这一现象是未经校正的预测无法获知的。

可见,经过聚类分组数为 3 时的预测校正,各肌肉

与基于逆向动力学的模拟结果差异很大,此时预测结果已反映出手部操作的影响。各肌电预测曲线间存在较强的同步性。为了得到更精细的校正,再增加最小聚类分组数到 4,此时的右斜方肌的实测与预测校正结果对比如图 16 所示。




图 16 斜方肌肌电实测与预测校正结果的对比

由图 14 - 图 16 可以认为,预测校正结果是基于肌肉行为划分的,可避免肌肉控制方式不确定造成的预测错误。图 16 反映出更多细节,但由于各聚类时段内,对 ANYBODY 模型的选择是基于秩相关性对比的,虽然各段内信号经过极差归一化处理,如时段较长,仍存在预测与实测绝对值差异较大的问题,如图 16 中 8 ~ 11 秒时段内偏差较大。随着细分程度增加到 7 左右,绝对值差异会随细分程度增加而下降,如图 10 - 图 13 所示。

综上,由于图 15 所示的各躯干肌肉的动作同步性,可以根据部分椎旁肌行为,校正至少部分躯干其他肌肉的预测结果。这种校正的细分程度可以改善预测精度,但对具体身体组织状态的预测效果需进一步确认。

方法的局限在于需要事先确认姿态及工作任务。预测还需要根据本人数据建立训练集。进一步的研究将确认对其他肌肉、骨骼和韧带的受力状态的校正效果,以及疲劳、性别、体重等因素的影响。

6 结 语

这种方法克服了躯干行为控制方式多样的难题,在 ANYBODY 预测模型的基础上,实现了对躯干肌肉行为的识别和肌电信号预测校正。所得行为划分结果能识别不同时段内的肌肉协作方式,进而标注动作意图。校正方法对个体行为特征敏感。躯干肌电预测结

果为基于躯干肌电的交互控制提供了精度更高、更易用的信号源,同时可用于校正躯干其他肌肉及被动组织的受力状态预测。

参 考 文 献

- [1] Mukhopadhyay A, Samui S. An experimental study on upper limb position invariant EMG signal classification based on deep neural network[J]. Biomedical Signal Processing and Control,2020,55:101669.
- [2] Cai S, Chen Y, Huang S, et al. SVM-based classification of sEMG signals for upper-limb self rehabilitation training[J]. Frontiers of Neuro robotics,2019,13:31 - 38.
- [3] Gu Y, Yang D, Huang Q, et al. Robust EMG pattern recognition in the presence of confounding factors: Features, classifiers and adaptive learning[J]. Expert Systems with Applications,2018,96:208 - 217.
- [4] Bi L, Feleke A, Guan C. A review on EMG-based motor intention prediction of continuous human upper limb motion for human-robot collaboration[J]. Biomedical Signal Processing and Control,2019,51:113 - 127.
- [5] Zhang H, Zhang Y, Zhong B, et al. A comprehensive survey of vision-based human action recognition methods[J]. Sensors,2019,19(5):1005.
- [6] Larivière C, Gagnon D, Loisel P. An application of pattern recognition for the comparison of trunk muscles EMG waveforms between subjects with and without chronic low back pain during flexion—extension and lateral bending tasks[J]. Journal of Electromyography and Kinesiology,2000,10(4):261 - 273.
- [7] Guo S, Pang M, Gao B, et al. Comparison of sEMG-based feature extraction and motion classification methods for upper-limb movement[J]. Sensors,2015,15(4):9022 - 9038.
- [8] Cai S, Chen Y, Huang S, et al. SVM based classification of sEMG signals for upper-limb self-rehabilitation training[J]. Front Neuro robotics,2019,13:31 - 38.
- [9] Nazmi N, Rahman A, Azizi M, et al. A review of classification techniques of EMG signals during isotonic and isometric contractions[J]. Sensors,2016,16(8):1304.
- [10] Bunderson N, Kuiken T. Quantification of feature space changes with experience during electromyogram pattern recognition control[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2012,20(3):239 - 246.
- [11] Kent P, Jensen R, Kongsted A. A comparison of three clustering methods for finding subgroups in MRI, SMS or clinical data: SPSS Twostep Cluster analysis, Latent Gold and SNOB[J]. BMC medical re-search methodology, 2014,14:113.