

基于表面肌电力映射矩阵的上肢运动方向预测模型

王 林¹, 李炜煌², 唐鸿雁²

(1. 香港理工大学 南京技术创新研究院, 南京 210036; 2. 上海理工大学 智能康复工程研究院, 上海 200093)

摘要: 针对表面肌电(sEMG)信号与上肢运动方向之间的映射关系, 提出一种基于肌电力映射矩阵的上肢运动方向预测模型。通过实验进行受试者肌电信号的采集, 分析上肢在不同姿态下的力方向识别算法的准确性。实验采用 9 块浅层肌肉的肌电信号作为输入, 运用小波滤波和均方根值(RMS)处理信号, 并构建了肌电力方向映射矩阵(SFMM)和末端运动方向映射矩阵(EDMM)。通过伪逆法和反向传播神经网络(BPNN)进行模型训练, 对比使用原始数据、处理后的数据以及结合位姿变换矩阵的数据这 3 种方法在单独姿态和混合姿态下的预测能力。研究结果显示, 结合位姿变换矩阵的方法在各种姿态下均表现出较高的预测准确度, 可有效减小上肢姿态变化对预测结果的影响。本研究为基于 sEMG 的外骨骼设备力方向预测提供了理论基础。

关键词: 表面肌电信号; 运动意图识别; 神经网络; 多姿态; 映射矩阵

中图分类号: F 830

文献标志码: A

A prediction model of upper limb motion direction based on the surface-electromyography force mapping matrix

WANG Lin¹, LI Weihuang², TANG Hongyan²

(1. Nanjing Technology and Innovation Research Institute, The Hong Kong Polytechnic University, Nanjing 210036, China;
2. Institute of Intelligent Rehabilitation Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: A prediction model for upper limb motion direction based on the electromyography force mapping matrix was proposed to map the relationship between surface-electromyography (sEMG) signals and the direction of upper limb motion. Electromyography signals of the subjects were collected through experiments, and the accuracy of the force direction recognition algorithm for the upper limb in different postures was analyzed. Electromyography signals of nine superficial muscles were used as input, with wavelet filtering and root mean square (RMS) applied to process the signals. Additionally,

收稿日期: 2025-01-22

基金项目: 国家自然科学基金资助项目(62403320); 上海市科学技术委员会资助项目(23YF1429900)

第一作者: 王 林(1994-), 男, 副研究员。研究方向: 并联机器人、康复机器人。E-mail: lin1wang@polyu.edu.hk

通信作者: 唐鸿雁(1992-), 男, 讲师。研究方向: 康复机器人、智能机器人。E-mail: hytang@usst.edu.cn

引文格式: 王林, 李炜煌, 唐鸿雁. 基于表面肌电力映射矩阵的上肢运动方向预测模型[J]. 上海理工大学学报, 2025, 47(1): 19-29.

Citation: WANG Lin, LI Weihuang, TANG Hongyan. A prediction model of upper limb motion direction based on the surface-electromyography force mapping matrix[J]. Journal of University of Shanghai for Science and Technology, 2025, 47(1): 19-29.

the sEMG-force direction mapping matrix (SFMM) and the end motion direction mapping matrix (EDMM) were constructed. The model was trained by pseudo-inverse method and back propagation neural network (BPNN). The prediction performance of directly using the original data, the processed data, and the data combined with the posture transformation matrix in single posture and mixed posture was compared through experiments. The research results show that the method combined with the posture transformation matrix shows high accuracy in various postures, which can effectively reduce the influence of upper limb posture changes on the prediction results. This study provides a theoretical basis for the force direction prediction of exoskeleton devices based on sEMG.

Keywords: *surface-electromyographic; motion intention recognition; neural network; multiple postures; mapping matrix*

人体运动高度依赖于肌肉收缩，在假肢控制、运动医学、人机交互和医疗康复等多个关键应用领域，准确测量肌肉收缩强度至关重要。虽然侵入性方法能够精确测量单块肌肉的力量，但是非侵入性估算技术因其对临床应用的更高适用性，已成为肌肉力量估算的重要研究方向，并广泛应用于实际中。

众多研究深入探讨了肌电图 (electromyogram, EMG) 与肌肉力量之间的线性与非线性关系。早期研究^[1-2]主要聚焦于恒定姿态和准恒定力收缩条件下，主动肌 EMG 与肌肉力量之间的线性关系。随后，研究向非线性关系拓展^[3-4]。为了进一步提升 EMG-扭矩估算的准确性，研究者们采取了一系列改进措施，包括对主动肌和拮抗肌活动进行建模，考虑不同受试者间的差异，采用白化 EMG 信号和/或多通道 EMG-扭矩估算器来减少变异性^[5]，以及纳入关节角度因素对 EMG-扭矩动力学进行建模，并采用鲁棒的系统识别方法^[6]。这些技术不仅深化了我们对 EMG 与肌肉力量关系的理解，还在假肢控制、临床生物力学和人体工程学评估^[7]等多个领域展现出了重要的应用价值。

基于 EMG 的假肢控制领域中，一个关键问题在于如何准确划分运动类别。为此，多个 EMG 特征 (如斜率变化率^[8]、零交叉率和平均波形长度^[9]等) 被用作输入特征。近年来，这些“附加”特征在 EMG 分类问题中的成功应用^[10]，促使学者们开始探索它们在 EMG-扭矩估算问题中的潜力。陆伟^[11]针对上肢多模态运动任务，通过活动段信号检测与特征选择，结合贡献度系数计算，成功实现了肌电力的实时准确预测。同时，Naeem 等^[12]也提出了一种新的反向传播神经网络 (back

propagation neural network, BPNN) 模型，将校正后的平滑 EMG 作为输入，构建了 EMG 信号与人体手臂肌电力之间的映射关系模型。然而，上述研究并未将表面肌电 (surface-electromyography, sEMG) 信号与上肢作用力方向进行关联。为此，本研究团队将基于上肢肌肉的运动学功能描述，构建表面肌电力映射矩阵，提出一种上肢力方向预测模型，以用于上肢外骨骼或上肢康复机器人的运动控制。

1 研究方法

1.1 实验平台设计

根据实验需要，本研究设计制作了表面肌电传感器、姿态传感器和六维力传感器，样品如图 1 所示。由图可见，9 块表面肌电传感器 (自行开发研制) 安装在肌电信号采集上位机中，通过绝缘线缆与贴片电极相连接。实验同时采集上位机和六维力传感器的力数据，并将所有信号进行整合，然后通过串口发送给上位机电脑。

实验共实施 10 次，所有实验数据均来自同一位受试者。受试者年龄 26 岁，身体健康状况良好。为了降低实验条件对结果的影响，确保受试者在每次实验中均保持充沛的精神和体力，实验分为间隔的 10 d 来完成，并统一安排在实验当天的 15:00 开始。

每次实验分为准备和采集两个阶段。准备阶段主要包括实验过程讲解、实验设备安装和调试，以确保实验能够正常进行。实验开始前，实验助手向受试者详细介绍当天的实验过程和注意事项，并询问受试者的身体状况。受试者准备就




图 1 传感器实物图

Fig.1 Sensor pictures

绪以后, 实验助手为其穿戴实验器具, 安装肌电传感器和姿态传感器, 如图 2 所示。实验主要采集 9 块肌肉肌电信号, 这些肌电信号分别是冈下肌、胸肌、肱二头肌、肱二头肌长头、肱三头肌外侧、肱三头肌内侧、肱桡肌、三角肌前部、三角肌后部。在为受试者贴戴电极片之前, 实验助手使用酒精擦拭受试者的皮肤表面, 并在贴片处涂上表面导电胶以增强导电性, 然后将 9 个电极片分别贴戴到受试者右侧上肢的相应肌肉上。当电极片贴戴完成后, 实验助手开始测试肌电传感器、姿态传感器和六维力传感器以及上位机软件, 从而确保所有实验设备和软件都运作正常。

采样阶段, 受试者分别采用 3 种姿态接受采样: 第一种, 端举姿态, 即受试者上臂保持竖直, 肘关节弯曲 90°(图 2(a)); 第二种, 前平举姿态, 即受试者上臂前伸, 同时保持肘关节弯曲微小角度(图 2(b)); 第三种, 侧平举姿态, 即受试者上臂外展, 同时保持肘关节弯曲微小角度(图 2(c))。实验过程中, 受试者全程端坐在椅子上, 保持上半身竖直, 右手紧握住固定在实验台上的六维力传感器, 对传感器手柄依次施加上、下、左、右、前、后 6 个方向的力, 每 6 次一个循环, 每天进行 10 个循环, 如图 2(e) 所示。为了避免受试者过度疲劳, 每组循环间隔 5 min。

1.2 数据采集与处理

手腕在三维空间的运动由肩关节 3 个方向的转动和肘关节的屈伸运动组成。实验采用 9 个表面肌电信号传感器来收集 9 块肌肉的肌电信号, 传感器的采样频率为 20 Hz。受试者所贴电极片位





图 2 数据采集实验

Fig.2 Data collection experiment

于所测肌肉的纤维方向上, 并处于肌肉块的中心处, 相邻电极片的距离为 2 cm。

受试者手部输出的力作用方向通过力方向传感器进行检测。力方向传感器可以检测 6 个方向上的压力, 产生的压力通过改变传感器的电阻, 从而输出模拟电压信号。两个九轴力传感器分别被固定在受试者的小臂和上臂上, 用来检测上肢的姿态, 姿态角采用从传感器输出的 3 个 $x-y-z$ 型欧拉角来描述。通过旋转矩阵, 可以求得肩部及肘部的运动转角。肌电信号、力方向传感器的信号通过工作站实时线上处理。肌电信号的工作带宽是 10~400 Hz, 受限于团队自主研发的肌电采集模块的计算能力, 所有信号采集频率都设置为 20 Hz。为了减少外界环境以及电路元器件(如电源信号)对肌电信号的干扰, 使用小波滤波对采集到的原始数据进行处理。由于均方根(RMS)值是一种简单的时域特征值, 故通过 RMS 值对过滤后的信号进行进一步处理。

1.3 理论方法

1.3.1 sEMG-运动方向映射矩阵

手臂运动由各种深层肌肉和浅层肌肉共同产生,然而,由于受到浅层肌肉的干扰,深层肌肉的信号难以通过肌电传感器检测到。因此,本文仅研究浅层肌肉。从解剖学角度来看,肱二头肌、胸肌、三角肌前部、三角肌后部、冈下肌、肱二头肌长头、肱三头肌外侧、肱三头肌内测和肱桡肌是手臂运动的主要驱动肌肉。各肌肉的活动分别对应着上肢的各种运动姿态,本研究提出的sEMG-运动方向映射矩阵(sEMG-force direction mapping matrix, SFMM),基于动态收缩数据来估计肌肉力量。

首先,根据解剖学原理建立身体、上臂和前臂的坐标系。对于身体坐标系,原点设置在胸部中央。 z 轴为垂直轴, y 轴为矢状轴, x 轴为冠状轴。对于上臂坐标系,原点设置在肩关节中心。 z 轴从肩关节指向肘关节, y 轴为标准姿态下的矢状轴, x 轴垂直于 z 轴和 y 轴。对于前臂坐标系,原点设置在肘关节中心。 z 轴从肘关节指向腕关节, y 轴为标准姿态下的矢状轴, x 轴垂直于 z 轴和 y 轴。然后,建立各个肌肉与姿态角之间的关系,如表1所示。表中: Rs_x 、 Rs_y 、 Rs_z 表示肩关

节绕 x 、 y 、 z 轴正向旋转, $R's_x$ 、 $R's_y$ 、 $R's_z$ 表示反向旋转; Re_x 、 Re_y 、 Re_z 表示肘关节绕 x 、 y 、 z 轴正向旋转, $R'e_y$ 表示绕 y 轴反向旋转。接下来,可以推导出肌肉与坐标变换之间的关系,用 M_{SFMM} 来表示,如式(1)所示。

$M_{SFMM} =$

$$\begin{pmatrix} 0 & a_{12} & a_{13} & 0 & a_{15} & 0 & 0 & 0 \\ 0 & a_{22} & 0 & a_{24} & a_{25} & 0 & 0 & 0 \\ a_{31} & 0 & 0 & a_{34} & a_{35} & 0 & 0 & 0 \\ a_{41} & 0 & a_{43} & 0 & 0 & a_{46} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & a_{56} & 0 & 0 \\ 0 & 0 & 0 & a_{64} & 0 & 0 & 0 & a_{68} \\ 0 & a_{72} & a_{73} & 0 & 0 & 0 & a_{77} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & a_{87} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & a_{98} \end{pmatrix}^T \quad (1)$$

式中, a_{ij} 是 M_{SFMM} 中第 i 行、第 j 列的元素,并且 a_{ij} 满足 $\sum_{i=1}^9 a_{ij} = 1$ 。

M_{SFMM} 是一个9行8列的矩阵,表示有9块被检测的肌肉和8种手臂旋转方式。为了计算手腕的力量方向,首先需要推导出上臂和前臂的两个姿态转换矩阵。肩关节具有绕 x 、 y 、 z 轴的3种旋转方式,这里采用 x - y - z 型的欧拉转换矩阵来描述上臂的姿态。同时,肘关节只有绕 y 轴的一种旋转方式。

$$T_{upper} = T_x T_y T_z = \begin{pmatrix} n_u & o_u & p_u \end{pmatrix} \begin{pmatrix} c\theta_x c\theta_z & -c\theta_y s\theta_z & s\theta_y \\ c\theta_z s\theta_x s\theta_y + c\theta_x s\theta_z & s\theta_x s\theta_y s\theta_z + c\theta_x c\theta_z & -c\theta_y s\theta_x \\ -c\theta_x c\theta_z s\theta_y + s\theta_x s\theta_z & c\theta_x s\theta_y s\theta_z + c\theta_z s\theta_x & c\theta_x c\theta_y \end{pmatrix} \quad (2)$$

$$T_{forearm} = T_{upper} T_{y'} = \begin{pmatrix} n_f & o_f & p_f \end{pmatrix} = \begin{pmatrix} c\theta_y c\theta_{y'} c\theta_z - s\theta_y s\theta_{y'} & -c\theta_y s\theta_z & c\theta_y c\theta_z s\theta_{y'} + c\theta_{y'} s\theta_y \\ c\theta_{y'} c\theta_z s\theta_x s\theta_y + c\theta_y s\theta_x s\theta_{y'} + c\theta_x c\theta_{y'} s\theta_z & c\theta_x c\theta_z - s\theta_x s\theta_y s\theta_z & -c\theta_y c\theta_{y'} s\theta_x + c\theta_z s\theta_x s\theta_y s\theta_{y'} + c\theta_x s\theta_{y'} s\theta_z \\ -c\theta_x c\theta_{y'} c\theta_z s\theta_y - c\theta_x c\theta_y s\theta_{y'} + c\theta_{y'} s\theta_x s\theta_z & c\theta_z s\theta_x + c\theta_x s\theta_y s\theta_z & c\theta_x c\theta_y c\theta_{y'} - c\theta_x c\theta_z s\theta_y s\theta_{y'} + s\theta_x s\theta_{y'} s\theta_z \end{pmatrix} \quad (3)$$

式中: θ_x 、 θ_y 、 θ_z 分别为绕 x 、 y 、 z 轴旋转的角度; c 代表余弦函数; s 代表正弦函数; n_u 、 o_u 、 p_u 分别代表 x' 、 y' 、 z' 轴的单位向量; n_f 、 o_f 、 p_f 分别代表 x'' 、 y'' 、 z'' 轴的单位向量。

当绕 x 轴方向的转动为主动运动时,运动方向可以计算为

$$d_{c,x} = n_u \times \text{norm}(e_w), e_w = l_u p_u + l_f p_f \quad (4)$$

其余的方向可以进行类似计算,结果如下:

$$\begin{cases} d_{a,x} = -n_u \times e_w \\ d_{c,y} = o_u \times e_w \\ d_{a,y} = -o_u \times e_w \\ d_{c,z} = p_u \times e_w \\ d_{a,z} = -p_u \times e_w \\ d_{c,y'} = o_f \times \text{norm}(e_w - e_e), e_e = l_f p_f \\ d_{a,y'} = -o_f \times \text{norm}(e_w - e_e) \end{cases} \quad (5)$$

式中: l_u 是上臂的长度; e_w 、 e_e 为中间变量; l_f 是前臂的长度; $\text{norm}(v)$ 表示向量 v 的单位向量;下标 c 、 a 分别代表顺时针和逆时针转动。

末端(手腕)的运动方向应为所有这些运动方向的总和。接下来,可以得到末端运动方向映射矩阵(end motion direction mapping matrix, EDMM)为

$$M_{EDMM} = \begin{pmatrix} d_{c,x} & d_{a,x} & d_{c,y} & d_{a,y} & d_{c,z} & d_{a,z} & d_{c,y'} & d_{a,y'} \end{pmatrix} \quad (6)$$

故,末端运动方向可以根据下式计算:

$$D = M_{EDMM} M_{SFMM} Q_{sEMG} \quad (7)$$

式中: D 表示末端运动方向; Q_{sEMG} 为表面肌电信号。

表 1 各肌肉功能的数学符号描述

Tab.1 Mathematical symbol description of each muscle function

肌肉	Rs_x	$R's_x$	Rs_y	$R's_y$	Rs_z	$R's_z$	Re_y	$R'e_y$
肱二头肌	0	a_{12}	a_{13}	0	a_{15}	0	0	0
胸肌	0	a_{22}	0	a_{24}	a_{25}	0	0	0
三角肌前部	a_{31}	0	0	a_{34}	a_{35}	0	0	0
三角肌后部	a_{41}	0	a_{42}	0	0	a_{46}	0	0
冈下肌	0	0	0	0	0	a_{56}	0	0
肱二头肌长头	0	0	0	a_{64}	0	0	0	a_{68}
肱三头肌外侧	0	a_{72}	a_{73}	0	0	0	a_{77}	0
肱三头肌内侧	0	0	0	0	0	0	a_{87}	0
肱桡肌	0	0	0	0	0	0	0	a_{98}

从式(7)中的矩阵可以看出, M_{EDMM} 是一个 3×8 的矩阵, M_{SFMM} 是一个 8×9 的矩阵, 而 Q_{sEMG} 是一个 9×1 的矩阵。因此, 结果必定是一个 3×1 的矩阵, 它表示手腕的运动方向。

1.3.2 伪逆求解算法

为了确定 SFMM 中的所有元素, 本研究采用了伪逆方法。从方程(7)可以看出, 该方程是一个线性方程, 包含 20 个未知元素。为了确定这些元素, 需要 20 个独立方程。然而, 在实验中可以获得大量数据, 这使得可以使用远多于 20 个的独立

方程来求解该方程组。因此, 这是一个超定系统, 采用伪逆方法进行求解是合适的。

$${}_kD = \begin{bmatrix} {}_kd_1 \\ {}_kd_2 \\ {}_kd_3 \end{bmatrix} = {}_kM_{EDMM} \cdot M_{SFMM} \cdot {}_kQ_{sEMG} =$$
$${}_kM_{EDMM} \cdot M_{SFMM} \begin{bmatrix} {}_k\varepsilon_1 \\ \vdots \\ {}_k\varepsilon_9 \end{bmatrix} \tag{8}$$

式中: ${}_kD$ 表示第 k 个数据的预测方向, ${}_kd_1$ 、 ${}_kd_2$ 、 ${}_kd_3$ 为其 3 个分量; ε_i 表示 9 块肌肉的肌电信号, $i=1, 2, \cdots, 9$ 。该方程可以转化为

$$\begin{bmatrix} {}_kd_1 \\ {}_kd_2 \\ {}_kd_3 \end{bmatrix} = {}_kM_{EDMM} \cdot {}_kE \cdot X =$$
$${}_kM_{EDMM} \begin{bmatrix} {}_k\varepsilon_3 \cdot {}_k\varepsilon_4 & \cdots & 0 \\ & {}_k\varepsilon_1 \cdot {}_k\varepsilon_2 \cdot {}_k\varepsilon_7 & \\ & & {}_k\varepsilon_1 \cdot {}_k\varepsilon_4 \cdot {}_k\varepsilon_7 \\ \vdots & & & {}_k\varepsilon_2 \cdot {}_k\varepsilon_3 \cdot {}_k\varepsilon_6 & \vdots \\ & & & & {}_k\varepsilon_1 \cdot {}_k\varepsilon_2 \cdot {}_k\varepsilon_3 \\ & & & & & {}_k\varepsilon_4 \cdot {}_k\varepsilon_5 \\ & & & & & & {}_k\varepsilon_7 \cdot {}_k\varepsilon_8 \\ 0 & \cdots & & & & & & {}_k\varepsilon_6 \cdot {}_k\varepsilon_9 \end{bmatrix} X \tag{9}$$

式中: ${}_kM_{EDMM}$ 是一个 3×8 的矩阵; ${}_kE$ 是一个 8×20 的矩阵; X 是一个 20×1 的矩阵。

对于含 n 帧数据的数据集 m , 等式可以转换为

$$D^m = M_{EDMM}^m E_{SFMM}^m X$$
$$\Leftrightarrow$$

$$\begin{bmatrix} {}_1D \\ {}_2D \\ \vdots \\ {}_nD \end{bmatrix} = \begin{bmatrix} {}_1M_{EDMM} & 0 & \cdots & 0 \\ 0 & {}_2M_{EDMM} & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & {}_nM_{EDMM} \end{bmatrix} \begin{bmatrix} {}_1E \\ {}_2E \\ \vdots \\ {}_nE \end{bmatrix} X \tag{10}$$

式中: D^m 是一个 $3n\times 1$ 的矩阵; M_{EDMM}^m 是 $3n\times 8n$ 的矩阵; E_{SFMM}^m 是一个 $8n\times 20$ 的矩阵; M_{EDMM}^m 、 E_{SFMM}^m 和 X 的乘积是一个 $3n\times 1$ 的矩阵。

为了节省计算资源, 可以在使用伪逆方法之前先计算矩阵 M_{EDMM}^m 和 E_{SFMM}^m 的乘积, 并将该乘积定义为一个 $3n\times 20$ 的矩阵 M^m 。然后, 使用伪逆方法来计算未知元素 X 。方程(10)可以等价地转换为以下形式:

$$D^m = M_{EDMM}^m E_{SFMM}^m X = M^m X$$
$$\Leftrightarrow$$
$$\left(M^{mT} M^m \right)^{-1} M^{mT} D^m =$$
$$\left(M^{mT} M^m \right)^{-1} M^{mT} M^m X = X \tag{11}$$

1.3.3 反向传播神经网络

反向传播神经网络(BPNN)是一种多层前馈网

网络，具有误差反向传播特性，是应用最广泛的网络之一。BPNN 通过 BP 算法生成，BP 算法是一种监督学习算法，通过不断循环计算网络的权重和误差值来调整和减小误差方向上的变化趋势，直到误差平方和达到最小。网络的权重和误差趋势与网络的误差呈正相关关系，并反向传播到每一层。BPNN 可以学习和存储大量没有数学表达式的输入-输出映射关系，可以用于映射柔性杆末端力与位置及方向之间的关系。BPNN 由输入层、输出层和多个隐藏层组成。本研究将柔性杆的位置和四元数作为输入层，手腕的力作为输出层。

1.4 预估算法

本文采用 BPNN 训练所有数据，在 BPNN 中，信息通过层与层之间的连接进行前向传播，并通过反向传播算法进行误差反向传递和权重更新，以最小化预测输出与实际输出之间的误差。BPNN 的输入信号是 9 块肌肉的肌电信号，目标输出是作用力的方向。在每次训练中，随机抽取 85% 的数据作为训练数据，15% 的数据作为检测数据。在训练环节中，使用 10 折交叉验证来训练相应的数据。

为了分析上肢姿态对力方向预测的影响，本文提出 3 种方法进行对比分析。

方法 1：直接训练法，直接使用实验数据进行训练。训练分为单独训练和整体训练两个部分。单独训练时，在每种上肢姿态的数据中随机抽取 85% 的数据用作训练数据，将采集到的数据直接作为 BPNN 的输入，将对应的力方向数据作为 BPNN 的输出，剩下的数据作为测试数据。整体训练时，将 3 种实验姿态采集到的数据拼接在一起，然后再采集 85% 的数据作为训练数据，剩下的作为测试数据进行 BPNN 训练。训练流程如图 3 所示。




图 3 方法 1 训练流程图
Fig.3 Training flowchart for method 1

方法 2：预处理训练法，使用处理过的实验数据进行训练。首先，对所有采集到的肌电信号数

据以及力方向数据进行小波滤波处理，将处理过的肌电信号转换为 RMS 值。然后，再对数据进行训练，同样分为单独训练和整体训练。单独训练时，从每种上肢姿态的数据中随机抽取 85% 的数据用作训练数据，剩下的数据作为测试数据。整体训练时，将 3 种处理过的数据拼接在一起，并采集 85% 的数据作为训练数据，剩下的作为测试数据进行 BPNN 训练。训练流程如图 4 所示。




图 4 方法 2 训练流程图
Fig.4 Training flowchart for method 2

方法 3：转换矩阵训练法，使用滤波后并乘以转换矩阵的实验数据进行训练。首先，对所有采集到的肌电信号数据以及力方向数据进行小波滤波处理，再将处理过的肌电信号转换为 RMS 值。然后，采用 RMS 型肌电信号数据乘以转换矩阵的方式，将得到的数据作为 BPNN 的输入。最后，对数据进行训练，同样分为单独训练和整体训练。单独训练时，在每种上肢姿态数据中随机抽取 85% 的数据作为训练数据，剩下的数据作为测试数据。整体训练时，将 3 种处理过的数据拼接在一起，并采集 85% 的数据作为训练数据，剩下的作为测试数据进行 BPNN 训练。训练流程如图 5 所示。




图 5 方法 3 训练流程图
Fig.5 Training flowchart for method 3

2 结果与分析

2.1 不同位姿下的结果


所有的实验数据都通过受试者身上的 9 个肌电信号传感器和力方向传感器采集得到。所得数据经过处理后，采用 3 种方法选择训练时的输入数据，这 3 种方法的输入信号分别如图 6 所示。

其中: 方法 1 直接使用了未经任何处理的肌电信号数据, 这些数据不连续, 且有局部激增情况, 但是和采集的力方向数据有明显的一一对应关系; 方法 2 对采集到的信号进行了小波滤波及 RMS 值处理, 处理后的数据较平滑、连续, 同时也与力方向数据相对应; 方法 3 的数据在方法 2 的基础上经过转换矩阵得到, 但是处理后的数据并不能直接显示出与力方向的对应关系。

深入分析这 3 种方法分别在不同姿态和混合姿态下的训练结果, 并用混沌矩阵进行表示。混沌矩阵是一个 7×7 的矩阵, 矩阵的行代表了实验

模型预测的力方向, 列代表了实验结果的力方向。实验只设置了前、后、左、右、上、下 6 个主要的代表性方向, 再加上一个没有力输出的停止状态, 最终形成一个 7×7 的矩阵。矩阵中每个元素代表了所在行的预测力方向与实际的实验力方向一致的样本点个数, 因此, 矩阵的对角线元素是预测结果与实验结果相吻合的样本点个数。显然对角线元素越大, 说明预测模型越准确。

图 7 为方法 1 分别在 3 种单独姿态和混合姿态下的仿真结果。从实验结果可以看出, 3 种单独姿态下, 识别准确度分别为 85.6%、73.3%、86.8%,



la 肱二头肌长头; pe 胸肌; de-f 三角肌前部; de-b 三角肌后部; in 冈下肌; bi 肱二头肌; tr-la 肱三头肌内侧; tr-lo 肱三头肌外侧; br 肱桡肌; $o_{u,x}$, $o_{u,y}$, $o_{u,z}$ 为 o_u 的分量; $e_{w,x}$, $e_{w,y}$, $e_{w,z}$ 为 e_w 的分量; $o_{f,x}$, $o_{f,y}$, $o_{f,z}$ 为 o_f 的分量

图 6 3 种方法的输入信号
Fig.6 Input signals for the three methods

而在混合姿态下，识别准确度下降为 59.3%。

图 8 中，方法 2 在 3 种单独姿态下，识别准确度都较高，分别为 89.9%、88.1%、92.8%，但在混合姿态下，识别准确度明显下降至 60.6%。

图 9 中，方法 3 在 3 种单独姿态和混合姿态

下，识别准确度都较高，分别为 88.7%、90.3%、91.5%、90.4%。

2.2 不同方法下的结果

从上述结果中可以看出，3 种方法训练结果的识别准确度差异很大。为了进一步对比 3 种方法

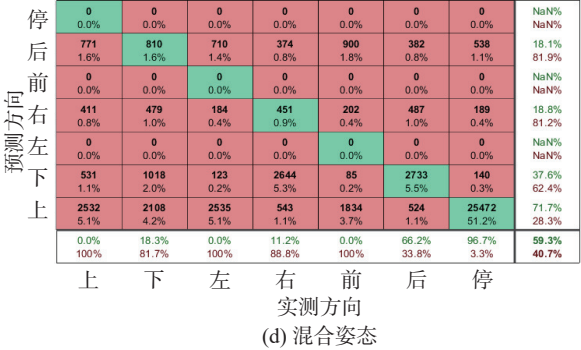
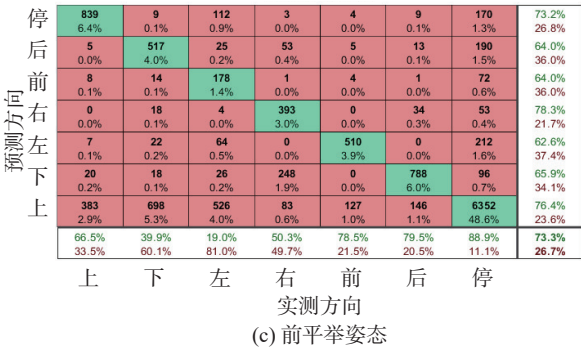
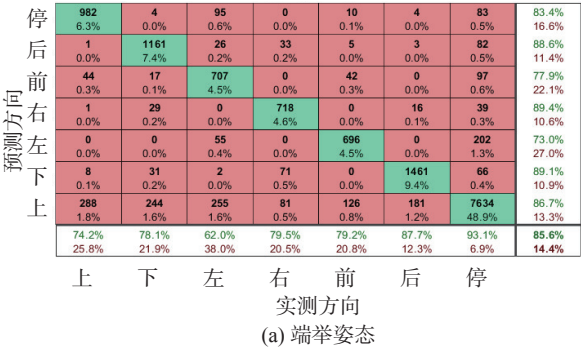


图 7 单独姿态和混合姿态下方法 1 的训练结果

Fig.7 Training results of method 1 in single postures and mixed posture

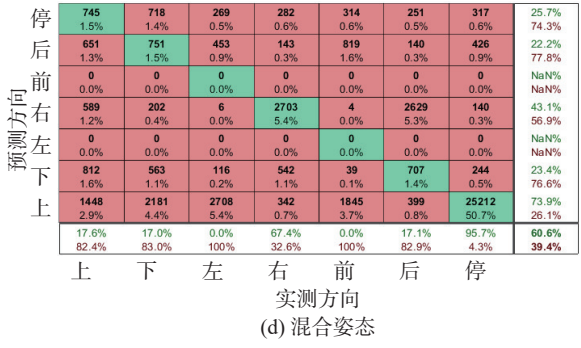
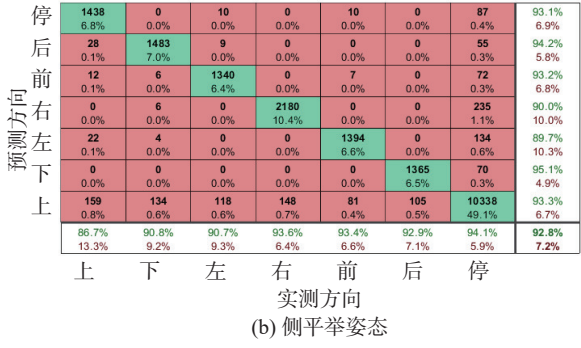




图 8 单独姿态和混合姿态下方法 2 的训练结果

Fig.8 Training results of method 2 in single postures and mixed posture




图 9 单独姿态和混合姿态下方法 3 的训练结果

Fig.9 Training results of method 3 in single postures and mixed posture

的性能差异, 本研究采用误差距离来横向对比 3 种训练方法的测试结果。第 i 个样本的误差距离 q_i 的计算公式为

$$q_i = \sqrt{\left[\sum_{j=1}^7 (f'_j - f_j)^2 \right] / 7}, i = 1, 2, \dots, N \quad (12)$$

式中: f_j 和 f'_j 分别为在 j 方向上的作用力测量值和预测值; N 是所有样本点的总和。

误差距离结果用箱线图来展示, 如图 10 所示。从图中可以看出, 所有方法的误差距离的中位值都接近 0, 这说明整体误差较小。同时, 各个方法的上边缘与上四分位数相差较大。方法 1 的上边缘与上四分位数较大, 说明方法 1 的误差分布较广。方法 2 和方法 3 在单独姿态时的上边缘与四分位数相差不多, 说明两者在单独姿态时识别准确度相似。但是在混合姿态时, 方法 1 和方法 2 的上边缘与上四分数以及中位数骤然增加, 误差分布变广, 而方法 3 的误差分布在各种情况下基本不变。

2.3 分析与讨论

通过对不同姿态下的实验结果进行分析后发现: 在单独姿态时, 方法 2 和方法 3 的识别准确度相当, 且高于方法 1, 这说明滤波可以将采集到的原始肌电信号中的噪音信号过滤掉, 从而提高识别准确度。在混合姿态时, 方法 1 和方法 2 的

识别准确度下降明显, 而方法 3 能保持同样的识别准确度, 这说明引入位姿变换矩阵可以降低位姿对识别准确度的影响。

同时, 研究也发现这 3 种方法具有一些共同点。一方面, 在不考虑停止状态下的实验结果时, 在上、下、左、右、前、后这 6 个方向之间相互鉴别出错的情况较少, 识别准确度较高, 这说明误差的主要来源都发生在对停止状态的识别上。另一方面, 从图 6 中可以看出, 在每个动作前后, 虽然力方向传感器已经有了输出数值, 但是还没有检测到肌电信号, 这说明在动作前后, 肌电信号较弱, 难以被传感器捕捉到, 需要通过提高传感器的测量灵敏度来改善训练结果。

在单独姿态下, 对实验数据进行训练得到的训练结果基本相同, 但是方法 1 和方法 2 在对整合数据进行处理时, 结果相差较大。而方法 3 的所有训练结果基本相同, 这说明了方法 1 和方法 2 受位姿变化影响大, 并不能直接作为测量手部力方向的方法。

未来的工作包含以下 3 个方面内容:

a. 本文提出的方法只能用于预估在各个姿态下的力方向, 而在实际应用时, 还需要预测力的大小才能判断能否驱动外骨骼等设备。因此, 在未来的研究中, 本研究团队将进一步评估在力方




图 10 单独姿态和混合姿态下 3 种方法的误差距离

Fig.10 Error distance of the three methods in single postures and mixed posture

向确定时力大小的预测模型。

b. 本文的研究数据来自身体上的多块肌肉，而绝大部分外骨骼使用者都有不同程度的肌肉损伤或缺失。因此，应进一步将此方法应用于这些外骨骼使用者身上来修正实验结果。

c. 采集数据时，本研究仅使用了上肢工作空间的 3 个较具代表性的姿态，且主要关注模型的预测能力，未能充分验证其在不同个体、不同姿态下的泛化能力。因此，本团队将在未来的研究中采用交叉验证等方法来评估模型的泛化能力，并确保其在不同个体和姿态下都能保持稳定的预测性能。此外，还将考虑采用迁移学习等技术手段来提高模型在不同环境下的适用性。

3 结 论

本文深入研究了表面肌电信号与上肢运动方向之间的映射关系，并提出了一种基于肌电力映射矩阵的上肢运动方向预测模型。通过系统的实

验设计与数据分析，探讨了 9 块浅层肌肉的肌电信号在预测上肢不同姿态下力方向的有效性。研究采用小波滤波和均方根值处理肌电信号，构建了肌电力方向映射矩阵和末端运动方向映射矩阵，并通过伪逆法和反向传播神经网络进行模型训练。实验结果表明，结合位姿变换矩阵的方法在各种姿态下均表现出较高力方向的预测准确度，显著优于直接使用原始数据或使用仅经过小波滤波和 RMS 处理的数据的方法。本文研究成果对减小上肢姿态变化对预测结果的影响具有一定参考价值，也为基于 sEMG 的外骨骼设备力方向预测提供了坚实的理论基础。

参考文献：

[1] BIGLAND B, LIPPOLD O C J. Motor unit activity in the voluntary contraction of human muscle[J]. *The Journal of Physiology*, 1954, 125(2): 322–335.

[2] GROSS J, TASS P A, SALENIUS S, et al. Cortico-muscular synchronization during isometric muscle

contraction in humans as revealed by magnetoencephalography[J]. *The Journal of Physiology*, 2010, 527(3): 623–631.

[3] BECK T W, HOUSH T J, JOHNSON G O, et al. Mechanomyographic and electromyographic responses during submaximal to maximal eccentric isokinetic muscle actions of the biceps brachii[J]. *Journal of Strength and Conditioning Research*, 2006, 20(1): 184–191.

[4] BARATTA R V, SOLOMONOW M, ZHOU B H, et al. Methods to reduce the variability of EMG power spectrum estimates[J]. *Journal of Electromyography and Kinesiology*, 1998, 8(5): 279–285.

[5] 王秀汝, 赵文汝, 刘金敬, 等. 肌电生物反馈治疗中枢神经系统损伤所致腕、踝关节异常运动模式的临床研究 [J]. *中国康复医学杂志*, 2004, 19(2): 108–110.

[6] 甄鑫, 董小雷, 蔡玉强. 人机环境中下肢关节扭矩动态估计的研究 [J]. *科技与创新*, 2023, (13): 26–29.

[7] 史小华. 坐/卧式下肢康复机器人研究 [D]. 秦皇岛: 燕山大学, 2014.

[8] 任小梅, 杨刚. 基于模糊聚类技术的肌电信号完全分解算法 [J]. *计算机应用*, 2016, 36(3): 878–882.

[9] 王金玮, 曹乐, 阚秀, 等. 基于表面肌电信号的 LDA-BPNN 双臂手势识别算法 [J]. *传感器与微系统*, 2023, 42(6): 158–160, 168.

[10] 孔康, 李德盈, 孙中圣. 基于小波包组合特征和 LMS-LSTM 的表面肌电信号分类 [J]. *电子技术应用*, 2022, 48(10): 92–96.

[11] 陆伟. 基于肌电信号的人体上肢肌力预测方法研究 [D]. 合肥: 中国科学技术大学, 2023.

[12] NAEEM U J, XIONG C H, ABDULLAH A A. EMG-muscle force estimation model based on back-propagation neural network[C]//2012 IEEE International Conference on Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS) Proceedings. Tianjin: IEEE, 2012: 222–227.

(编辑: 丁红艺)

(上接第 9 页)

[22] PATTNAIK G, SHRIVASTAVA V K, PARVATHI K. Transfer learning-based framework for classification of pest in tomato plants[J]. *Applied Artificial Intelligence*, 2020, 34(13): 981–993.

[23] KHAN M A, ZHANG Y D, SHARIF M, et al. Pixels to classes: intelligent learning framework for multiclass skin lesion localization and classification[J]. *Computers & Electrical Engineering*, 2021, 90: 106956.

[24] CHATO L, REGENTOVA E. Survey of transfer learning approaches in the machine learning of digital health sensing data[J]. *Journal of Personalized Medicine*, 2023, 13(12): 1703.

[25] KHAN M A, AKRAM T, ZHANG Y D, et al. Attributes based skin lesion detection and recognition: a mask RCNN and transfer learning-based deep learning framework[J]. *Pattern Recognition Letters*, 2021, 143: 58–66.

[26] 仇旭阳, 黄影平, 郭志阳, 等. 基于深度学习的障碍物检测与深度估计 [J]. *上海理工大学学报*, 2020, 42(6): 558–565.

[27] SHI Z C, SHANG Y, ZHANG X F, et al. DLT-lines based camera calibration with lens radial and tangential distortion[J]. *Experimental Mechanics*, 2021, 61(8): 1237–1247.

(编辑: 丁红艺)