

# 采用鱼群算法进化极限学习机的假脚步态识别\*

刘 磊<sup>1,2</sup>, 陈增强<sup>2</sup>, 杨 鹏<sup>3</sup>, 刘作军<sup>3</sup>

(1. 郑州轻工业大学建筑环境工程学院 郑州, 450002)

(2. 南开大学人工智能学院 天津, 300350)

(3. 河北工业大学人工智能与数据科学学院 天津, 300130)

**摘要** 为提高下肢假脚步态识别的准确性, 提出一种基于鱼群(fish swarm, 简称 FA)算法优化极限学习机(extreme learning machine, 简称 ELM)的模式识别方法。首先, 提取张量投影特征, 分析了特征值选取的合理性; 其次, 采用主成分分析法降维; 最后, 利用鱼群算法进化极限学习机分类识别平地行走、上楼、下楼、上坡及下坡 5 种步态, 识别准确率达到 97.45%。通过实验比较了该算法与极限学习机等分类器在假脚步态分类上的识别准确率与识别时间, 结果表明, FA-ELM 方法识别准确率优于其他方法。

**关键词** 表面肌电信号; 极限学习机; 鱼群算法; 步态识别; 智能假肢

**中图分类号** TH24

## 引 言

随着交通事故、工伤、自然灾害等意外伤害的发生, 假肢的研究越来越受到重视。中川昭夫等研究了气动式摆动相控制膝关节<sup>[1]</sup>。英国的 Blatchford 公司和德国的 Otto Bock 公司先后研制出了可以自动识别有限路况的智能仿生假肢<sup>[2]</sup>。冰岛的 Ossur 公司推出新款智能仿生膝关节 RHEO KNEE 3<sup>[3]</sup>。大阪大学采用磁流变阻尼器设计踝关节假肢<sup>[4-7]</sup>。近年来, 国内也有越来越多的大学和研究相继开发了智能假肢<sup>[8-11]</sup>。

要想对假肢进行灵活控制, 必须准确识别残疾人的步态。目前常用的步态识别信号源有角度、加速度、表面肌电信号(surface electromyography, 简称 sEMG)等信息。由角度、加速度传感器等组成的物理传感器网络不仅会使假肢穿戴者感觉累赘, 还会由于人体运动与反映意图的神经冲动之间存在自然的电-机延时现象, 致使假脚步态的识别存在滞后。在步态识别研究中, 视频信号和 sEMG 都有着较为广泛的应用, sEMG 相比于视频信号获取方式更为直接, 其采集方式更加适用于智能假肢装置, 因此笔者将 sEMG 作为控制信号源实现假脚步态识

别。现有的基于 sEMG 假脚步态识别方法, 首先采集受试者 sEMG 信号, 提取 sEMG 的绝对值积分、过零次数、中值频率及小波(包)变换系数等时域、频域、时频域特征, 然后采用支持向量机(support vector machine, 简称 SVM)、ELM 和线性判别分析(linear discriminate analysis, 简称 LDA)等分类算法识别出不同的步态。文献[9]研究结果表明, ELM 方法识别率要优于 SVM 和 LDA 等方法, 但是 ELM 正则化参数在一定数值范围内的微小变化会影响 ELM 分类精度。上面在 sEMG 数据处理过程中仅考虑了通道和时间 2 个维度的信息, 张量分解方法能够有效地分析时域、频域及空域等多维信息。为了从空间、频率、时间及任务等多维度描述肌电信号, 笔者从 sEMG 信号的张量数据中提取特征, 寻找投影矩阵, 以获取特征值。分类器的设计是步态识别关键环节之一, 为了克服 ELM 方法中正则化参数在一定范围内的变化会影响 ELM 识别准确率的缺点, 笔者对特征值选取核函数进行空间映射, 利用 FA 优化 ELM 参数, 最后利用 FA-ELM 识别步态并与粒子群算法(particle swarm optimization, 简称 PSO)优化的 ELM 进行对比, 实验结果表明, 张量投影矩阵能有效表征平地行走、上楼、下楼、上坡及下坡的特征, 鱼群算法优化极限学习机方法

\* 国家自然科学基金资助项目(61773151, 61703135); 河南省高等学校重点科研资助项目(18A413014); 郑州轻工业大学博士基金资助项目(0314-13501050006); 郑州轻工业大学校级青年骨干教师资助项目(0314-13502010001)  
收稿日期: 2018-11-16; 修回日期: 2019-01-10

对于假肢步态识别有良好的准确性, 优于 SVM 和 ELM 等方法。

## 1 实验方法

### 1.1 基于张量投影特征的表面肌电信号特征表示

令  $\{X_{jm}, j=1, 2, \dots, M\}$  是张量空间  $R^{I_1} \otimes R^{I_2} \dots \otimes R^{I_N}$  中的  $M$  个训练样本组成的集合, 其中:  $R^{I_1}, R^{I_2}, \dots, R^{I_N}$ , 为  $N$  个向量的线性空间, 则集合中的每一个元素  $X_j \in R^{I_1 \times I_2 \times \dots \times I_N}$ , 其中  $I_n (n=1, 2, \dots, N)$  为张量的维数, 共  $n$  种模式。表面肌电信号的张量表示就是定义一个多线性变换矩阵  $\{\tilde{U}_{(n)} \in R^{I_n \times P_n}, n=1, 2, \dots, N\}$ , 将原始张量空间  $R^{I_1} \otimes R^{I_2} \otimes \dots \otimes R^{I_N}$  映射到  $R^{P_1} \otimes R^{P_2} \otimes \dots \otimes R^{P_N} (P_n < I_n, n=1, 2, \dots, N)$  中, 即

$$Y_j = X_j \times \tilde{U}_{(1)}^T \times \tilde{U}_{(2)}^T \times \dots \times \tilde{U}_{(N)}^T \quad (1)$$

其中:  $\times$  表示张量乘积;  $\otimes$  表示克罗内克积;  $Y_j \in R^{P_1} \otimes R^{P_2} \otimes \dots \otimes R^{P_N}, j=1, 2, \dots, M$ 。

对于第  $n$  种模式, 内积矩阵  $\Phi^{(n)} = \sum_{j=1}^M \Phi_j^{(n)T} \Phi_j^{(n)}$  和外积矩阵  $\tilde{\Phi}^{(n)} = \sum_{j=1}^M \Phi_j^{(n)} \Phi_j^{(n)T}$  具有  $r^{(n)} = \min(I_n, I^{(n)})$  个非零特征值  $\lambda_i^{(n)}, i=1, 2, \dots, r^{(n)}$ , 其中,  $I^{(n)} = I_1 + \dots + I_{n-1} + \dots + I_N$ 。令  $v_i^{(n)}$  表示内积矩阵  $\Phi^{(n)}$  第  $i$  个特征值  $\lambda_i^{(n)}$  对应的特征向量,  $u_i^{(n)}$  表示外积矩阵第  $i$  个特征值  $\lambda_i^{(n)}$  对应的特征向量, 二者满足关系  $u_i^{(n)} = \lambda_i^{-\frac{1}{2}} \sum_{j=1}^M \Phi_j^{(n)T} v_i^{(n)}$ 。

令  $X_{j(n)}$  表示第  $j$  个样本的  $n$  模式矩阵, 则

$$\Phi_j^{(n)} = X_{j(n)} \tilde{U}_{\Phi}^{(n)} \quad (2)$$

$$\tilde{U}_{\Phi}^{(n)} = \tilde{U}_{(n+1)} \otimes \tilde{U}_{(n+2)} \otimes \dots \otimes \tilde{U}_{(N)} \otimes \tilde{U}_{(1)} \otimes \tilde{U}_{(2)} \otimes \dots \otimes \tilde{U}_{(n-1)} \quad (3)$$

原始数据的均方长度, 即  $\|m\|^2$  可以定义为

$$\|m\|^2 = \frac{1}{T} \sum_{j=1}^M (\Phi_j^{(n)} I_m)^T \Phi_j^{(n)} I_m = I_m^T \left( \frac{1}{M} \sum_{j=1}^M \Phi_j^{(n)T} \Phi_j^{(n)} \right) I_m \quad (4)$$

其中:  $m = \Phi_j^{(n)} I_m; I_m = \left( \frac{1}{I^{(n)}} \right) I; I$  为  $I^{(n)} \times 1$  维的全 1 列向量; 下标  $m$  表示均值。

假设内积矩阵的奇异值  $\sum_{j=1}^M \Phi_j^{(n)T} \Phi_j^{(n)} = V \Lambda V^T$ , 特征向量为  $V$ , 对应的特征值按照降序排列为  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{I^{(n)}})$ , 因此

$$\|m\|^2 = I_m^T \left( \frac{1}{M} \sum_{j=1}^M \Phi_j^{(n)T} \Phi_j^{(n)} \right) I_m = \frac{1}{M} \sum_{i=1}^r (\lambda_i^{\frac{1}{2}} v_i^T I_m)^2 \quad (5)$$

其中: 系数  $(\lambda_i^{\frac{1}{2}} v_i^T I_m)^2$  为均值向量值。

令集合  $M$  的  $n$  模式子集合  $M^{(n)}$  包含  $(P_n, P_n < r^{(n)})$  个最大均值向量对应的特征值索引, 计算前  $p_n$  个较大均值向量值对应的均值向量来组成投影变换矩阵  $\{\tilde{U}^{(n)} \in R^{I_n \times P_n}, n=1, 2, \dots, N\}$ , 并通过式(1)将原始张量数据投影到低维子空间中。

高斯小波在时域和频域上有良好的分辨率, 因此笔者选择高斯小波构建张量投影特征。高斯小波采用高斯函数  $\varphi(t) = e^{i2\pi Jt} e^{-\frac{t^2}{K}} / \sqrt{\pi K}$ , 采样信号  $x(t)$  在时间  $t_0$  与尺度  $a$  上的小波系数表示为

$$X(t_0, a) = \frac{1}{\sqrt{a\pi K}} \sum_{n=-\infty}^{\infty} (e^{i2\pi J \frac{t_n - t_0}{a}} e^{-\frac{(t_n - t_0)^2}{a^2 K}}) x(t_n) \quad (6)$$

其中:  $J$  为中心频率;  $K$  为带宽参数。

笔者经过高斯小波变换建立了一个 4 阶张量。sEMG 数据具有通道  $\times$  时间  $\times$  任务三维结构, 经过高斯小波变换后构建的张量数据具有通道  $\times$  频率  $\times$  时间  $\times$  任务 4 维结构。

### 1.2 鱼群算法进化极限学习机

极限学习机可以看作是单隐层网络, 内部为全连接。其中输入层、隐含层和输出层的神经元数目分别为  $n, l$  和  $m$ , 如图 1 所示。ELM 将神经网络训练过程简化为矩阵求逆问题, 学习速度明显提高。




图 1 极限学习机网络结构

Fig. 1 Extreme learning machine network structure

笔者采用鱼群算法优化 ELM 参数。图 2 为鱼群算法中人工鱼的视野和移动步长示意图, 表示人工鱼当前位置, 其视点在某一时刻停留的位置为  $X_v$ , 若该位置  $X_v$  的食物浓度高于当前位置  $X$  的浓度, 则人工鱼向食物方向前进一步到达  $X_n$ ; 反之则搜索其他方向的食物。

图 2 中, 人工鱼群当前位置为  $X =$




图 2 人工鱼的视野和移动步长

Fig. 2 Artificial fish vision and moving step length

$(x_1, x_2, \dots, x_n)$ , 视野所看到的位置为  $X_V = (x_1^v, x_2^v, \dots, x_n^v)$ , 寻找食物的过程为

$$x_i^v = x_i + Vr \quad (i = 1, 2, \dots, n) \quad (7)$$

$$X_n = \frac{X_V - X}{X_V - X} Sr \quad (8)$$

其中:  $r$  为  $[-1, 1]$  之间的随机数;  $S$  为移动步长;  $x_i$  为人工鱼初始位置;  $X_n$  为人工鱼移动后的位置。

由于环境里的其他人工鱼数目是有限的, 因此人工鱼改变自身位置的方法仍与式(8)相同。

## 2 下肢假肢步态识别实验

### 2.1 实验方案

实验过程中, 10 位大腿截肢患者参与了本研究的步态识别实验, 其中男性大腿截肢患者 6 名, 女性大腿截肢患者 4 名, 基本资料如表 1 所示。楼梯有 10 级台阶, 台阶高度为广泛应用的 150mm; 斜坡是无障碍通道的  $10^\circ$  斜坡; 平地实验在宽阔的室外走廊中进行。使用美国 Noraxon 公司的 MyoTrace400 采集 sEMG, 该设备可以同时采集 8 块肌肉的肌电信号。笔者参考文献[12-14]选择股直肌、缝匠肌、阔筋膜张肌、半膜肌、半腱肌和大收肌为表面肌电信号采集肌肉群。实验前, 受试者残肢端的体毛剔除, 不能做剧烈运动。每位受试者采集平地行走、上楼、下楼、上坡、下坡 5 种步态的表面肌电信号各 100 组, 共采集了  $100 \times 5 \times 10$  组数据。2 500 组作为训练集, 2 500 组作为测试集。为了消除步速差异对步态识别的影响, 每位受试者速度均匀地行走。笔者采用文献[12]的方法确定每路肌电的起始点。在实时处理表面肌电信号的过程中, Abel 等[15]已证明最合适的窗口大小为 150~300ms。笔者采用 300ms 小段数据进行特征值提取和步态识别。

大腿截肢者穿戴被动式假肢在平地行走时健肢侧与假肢侧能够实现交替运动, 在上、下楼梯与上、下坡时不能实现健肢侧与假肢侧的交替运动。上楼梯与上斜坡均为健肢先运动然后假肢跟随运动, 健肢保证在残肢前方; 下楼梯与斜坡假肢保持在健肢前方, 假肢先运动, 健肢快步跟上。本实验中平地行走、下楼、下坡先迈残肢; 上坡、上楼先迈健肢。肌电信号的幅值作为肌肉收缩力的间接反映, 两者并非一一映射关系, 需要建立不同实验对象和步态的参考标准。为了克服该问题, 通常选择参考值进行归一化处理。常用的方法是选择最大自主收缩值作为肌肉收缩的参考[16], 消除实验条件的影响, 将测试值由毫伏值转化为所选参考值的百分数, 如图 3 所示。幅值归一化处理并不是改变 sEMG 曲线的形状, 只是改变 y 轴的缩放比例。时间归一是在单步周期内选取均布的 300 个离散点, 将连续的肌电信号变成 1 个 1 维数组, 进而利用同等动作条件下的多个有效单步周期进行平均, 得到该步态的单步肌电模型。




图 3 归一化分析后的 sEMG

Fig. 3 After the normalized analysis of sEMG

表 1 受试者情况统计表

Tab. 1 The subjects of statistics

受试者	性别	年龄	残肢长度比例	假肢型号	穿戴时间/月
S1	男	25	31.2	奥托 3E80	22
S2	男	17	33.5	奥托 3R78	48
S3	男	23	27.4	C-Leg	10
S4	男	19	32.9	奥索 7 轴	36
S5	男	44	51.4	奥托 3280	13
S6	男	26	37.6	850	13
S7	女	23	28.8	德林 JB810	36
S8	女	33	41.3	奥托 3E80	22
S9	女	27	33.9	迈迪	19
S10	女	22	30.4	迈迪	15

## 2.2 步态特征提取与降维

按照 1.1 节方法计算出投影矩阵  $\tilde{U}^{(k)}$  ( $k=1, 2, \dots, n$ ) 后,笔者将构建好的高阶训练集张量  $\mathbf{A}_{tr}$  和测试集张量  $\mathbf{A}_{ts}$  分别投影到共同的投影矩阵中,得到如下张量特征

$$\begin{cases} \mathbf{G}_{tr} = \mathbf{A}_{tr} \times \mathbf{U}_1^T \times \mathbf{U}_2^T \times \mathbf{U}_3^T \\ \mathbf{G}_{ts} = \mathbf{A}_{ts} \times \mathbf{U}_1^T \times \mathbf{U}_2^T \times \mathbf{U}_3^T \end{cases} \quad (9)$$

在 sEMG 的张量表示中,中心频率  $J$  和带宽参数  $K$  是影响识别结果的重要参数,笔者采用 10 折交叉验证方法来选取  $J$  和  $K$ 。利用 ELM 分类器分类识别,将  $J$  和  $K$  分别取  $[-10, 10]$ ,对不同  $(2^J, 2^K)$  组合分别训练 ELM,识别率最高的一个组合为最优  $J$  和  $K$ 。 $2^J$  的取值为  $(2^{-10}, 2^{-9}, \dots, 2^9, 2^{10})$ , $2^K$  的取值为  $(2^{-10}, 2^{-9}, \dots, 2^9, 2^{10})$ 。图 4 中,当  $2^J=2, 2^K=0.5$  时得到的识别准确率最高。




图 4 中心频率  $J$  和带宽参数  $K$  的选择结果

Fig. 4 Center frequency  $J$  and bandwidth  $K$  parameter selection results

sEMG 原始数据为  $6 \times 300 \times 180$  (通道  $\times$  时间  $\times$  任务),经过高斯小波变换后成 4 阶张量,即  $6 \times 12 \times 50 \times 180$  (通道  $\times$  频率  $\times$  时间  $\times$  任务),3 个投影矩阵分别为  $\mathbf{U}^{6 \times 3}$ ,  $\mathbf{U}^{18 \times 9}$  和  $\mathbf{U}^{100 \times 16}$ 。数据投影和矩阵化后,每一个任务的特征维数为  $Z = 3 \times 9 \times 16 = 432$ ,原始数据对应的特征维数  $Z = 6 \times 300 = 1800$ 。与原始数据相比,张量特征的维数已经缩小很多。

张量特征的维数较高,如果直接作为分类器的输入向量,将导致训练过于复杂,因此还需要对特征值进行降维。主成分分析 (principal component analysis, 简称 PCA) 是一种降维的有效方法,其基本思想是选取主成分累计贡献率大于 95% 的前  $N$  列主成分。实验表明,取前 36 主成分时,累计贡献率可达 96.27%。

## 2.3 不同特征值比较分析

sEMG 的特征提取通常有时域法、频域法、时频域法等。常用的时域特征有均方根 ( $A_1$ )、肌电积分值 ( $A_2$ )、绝对均值 ( $A_3$ )、过零率 ( $A_4$ )、斜率符号变化数 ( $A_5$ ) 和波长 ( $A_6$ )。时域方法计算量小,运算复杂度不高。常用的频域特征包括峰值频率 ( $A_7$ )、平均功率频率 ( $A_8$ ) 等。常用的时频特征值有小波变换系数、小波系数绝对值最大值 ( $A_{10}$ ) 等。

为了说明本研究特征提取的有效性,采用 SVM 作为模式分类器对提取的特征进行分类,采用径向基核函数作为 SVM 的核函数。图 5 给出了采用不同的单一特征时的平均识别准确率和方差对比,可见肌电信号的大部分时域特征和频域特征识别准确率较低。由图 5 可以看出,在所有的特征提取算法中,张量特征 ( $A_9$ ) 表现出最好的分类准确率,张量特征方法识别率最高,稳定性最好,其代表性、分离度更好。这是因为张量特征能够从时间、空间、频率等多个模态上提取肌电信号的有效信息,因此,笔者选用张量特征作为步态模式识别的特征值。




图 5 采用不同单一特征时的平均识别准确率和方差对比  
Fig. 5 Using different average recognition accuracy at the time of single feature and variance contrast

笔者采用戴维斯和唐纳德指数 (davies-bouldin index, 简称 DBI) 来评价 sEMG 特征的区分度。DBI 的值越小,特征的区分度越好。不同特征值的 DBI 值如图 6 所示。由图 6 看出,采用张量特征提取方法 DBI 最小,明显优于其他特征提取方法。

## 2.4 不同 ELM 参数优化方法比较

分类器的设计是步态识别最后一个环节。ELM 参数确定的过程相对简单,核函数参数  $Q$  和




图 6 采用不同特征时的 DBI 指标对比

Fig. 6 Using different characteristics of the class DBI index contrast

正则化参数  $C$  是影响识别结果的重要参数。多次实验后,笔者选择小波核函数的 ELM 分类器,因此采用小波核函数设计 ELM 分类器,利用鱼群寻优算法得到最优  $C$  和  $Q$ 。极限学习机的正则化参数  $C$  搜索范围设置为  $(0, 120)$ ,小波核函数参数  $Q$  的搜索范围设置为  $(0, 80)$ 。AF 中的参数进行初始化设置:最大迭代次数为 100,  $V=3.2, S=0.6$ 。笔者将分类过程中的 10 折交叉验证识别率作为网格搜索法、PSO 及 FA 的适应度函数。式(10)为适应度函数,  $K=10, x_{ir}$  与  $x_{iw}$  为第  $i$  次测试集中正确和错误识别的样本数目。用二进制计数方式对 5 种步态定义:平地行走为  $(1, 0, 0, 0, 0)$ ;上楼为  $(0, 1, 0, 0, 0)$ ;下楼为  $(0, 0, 1, 0, 0)$ ;上坡为  $(0, 0, 0, 1, 0)$ ;下坡为  $(0, 0, 0, 0, 1)$ 。识别准确率是衡量识别效果的重要参数,定义如下

$$F = \frac{1}{K} \sum_{i=1}^K \frac{x_{ir}}{x_{ir} + x_{iw}} \quad (10)$$

图 7 为正则化参数  $C$  和 ELM 核函数参数  $Q$  的优化过程,最终得到最优解  $C=112.60, Q=75.48$ 。笔者采用文献[17]提出的 PSO 优化方法确定 PSO 参数。由表 2 可以看出:网格搜索优化方法 5 种步态的识别率在 82.51%~89.17%之间,平均识别率为 85.64%;而采用 PSO 优化后,除了下楼,其余步态的识别率均在 90%以上,平均识别率达到了 92.8%,但仍低于 FA 参数优化方法识别率;FA 参数优化方法比 PSO 参数优化方法平均识别率提高了 4.6%;网格法只对经验范围进行寻优,是一种局部寻优算法,所以识别率最低。FA 参数优化方法能够更准确、更有效地找到正则化参数和 ELM 核参数的优化组合值,因此笔者采用 FA 优化 ELM 的分类方法。

表 2 不同 ELM 参数优化方法识别准确率

Tab. 2 Different ELM identification accuracy parameter optimization method %

ELM 参数 优化方法	网格搜索 方法	PSO 优化 方法	FA 优化方法
平地行走	84.29 ± 1.24	91.87 ± 1.85	94.28 ± 1.68
上楼	89.17 ± 2.09	92.63 ± 3.16	96.34 ± 2.55
下楼	83.68 ± 1.77	88.16 ± 2.77	97.07 ± 3.07
上坡	79.46 ± 1.83	94.29 ± 2.82	98.95 ± 2.69
下坡	82.51 ± 2.45	94.17 ± 1.53	95.09 ± 2.42
平均	83.45 ± 1.96	92.21 ± 2.09	98.14 ± 2.36




图 7 最优解的变化

Fig. 7 The change of the optimal solution

### 2.5 不同方法比较分析

为了说明本算法的有效性,做了对比实验,用笔者所述的特征提取方法提取的张量特征作为特征值输入 BP 神经网络、SVM 和 ELM 分类器。对于训练集和测试集数据都使用 10 折交叉验证分类效果,如表 3 所示。鱼群算法进化 ELM 作为分类器的假肢步态识别方法,对每种步态的识别率均达到 90.45%以上。由表 3 可以看出,笔者提出的鱼群算法进化 ELM 算法明显优于传统的 BP 神经网络、SVM 等方法,这主要是因为 BP 神经网络易于陷入过学习,导致识别率不高。ELM 方法 5 种步态的识别准确率与 BP 算法比较有不同程度的提升,其中平地行走识别率提升较少,提升了 2.15%,下楼提升最多,提高将近 6.73%。AF-ELM 分类器的识别率高于没有经过参数优化的 ELM 分类器,说明优化后的 ELM 得到全局最优解,使步态整体识别率得到改善。

本研究使用的计算机平台为 32 位 Windows 操作系统,2.50 GHz Intel core Quad CPU 处理器,4G 内存,Matlab R2010b 软件被用于分析与处理实

表 3 不同分类器的步态识别准确率比较

Tab. 3 Gait recognition accuracy comparison of different classifiers

步态	BP	SVM	ELM	FA-ELM	%
平地行走	88.18 ± 2.86	89.36 ± 2.52	90.92 ± 1.07	97.47 ± 1.25	
上楼	85.35 ± 2.33	87.09 ± 2.71	88.26 ± 3.06	96.59 ± 2.94	
下楼	86.64 ± 2.39	84.47 ± 2.81	92.75 ± 3.66	98.77 ± 2.81	
上坡	86.77 ± 1.65	87.59 ± 3.05	91.19 ± 1.93	95.34 ± 2.62	
下坡	85.26 ± 3.94	87.18 ± 3.28	90.38 ± 1.86	97.42 ± 2.75	

验数据。5 种步态不同算法分类时间如表 4 所示:BP 神经网络学习速度较慢;而 SVM 由于采用一对一多分类模型,每次只能区分 2 种步态,SVM 分类器在步态平均识别时间方面高出 ELM 近 17.85%;由于 ELM 不需要调整网络输入权值,其分类时间小于 SVM;而本研究采用的 FA-ELM 的识别时间长于 ELM 方法,但是其识别平均准确率为 97.45%。因此最终选择 FA-ELM 分类器进行分类识别。

表 5 给出了识别时间的比较,识别时间包括特征提取、特征值降维和分类识别的时间。张量投影方法能够从时间、空间等多个模态上提取肌电信号的有效信息,然而高维度计算提高了算法的复杂度,带来了运行时间较长的问题。张量投影通过 PCA 降维处理后,有效缩短了分类时间。张量投影特征结合 PCA 降维处理后能够综合反映步态特征的结

表 4 不同算法分类时间比较

Tab. 4 Time to compare different algorithms classification

步态	ELM	FA-ELM	SVM	BP
平地行走	0.121 4	0.989 3	1.887 5	2.280 5
上楼	0.192 7	1.105 6	1.967 2	2.135 9
下楼	0.220 6	0.972 5	1.984 8	2.147 6
上坡	0.318 5	0.893 2	1.980 6	2.176 6
下坡	0.367 3	0.882 5	2.097 4	2.428 3
平均时间	0.226 6	0.954 7	1.980 4	2.220 5

构信息,缩短了分类时间。FA 参数优化方法能够更准确、更有效地找到正则化参数和 ELM 核参数的优化组合值,因此 FA-ELM 分类方法时间长于 ELM 方法。本研究方法可用于对识别精度有较高要求的离线分析中,在系统实时应用方面还有待改进。

表 5 不同算法识别时间比较

Tab. 5 Time to compare different algorithms classification

算法	特征提取时间/s	特征值降维时间/s	分类时间/s	识别准确率/%
张量特征+ELM	9.568	—	2.957 0	88.72
张量特征+FA-ELM	9.384	—	5.436 0	91.67
张量特征+PCA+ELM	9.249	2.415	0.226 6	90.31
张量特征+PCA+FA-ELM	9.762	2.526	0.954 7	97.45

### 3 结束语

以表面肌电信号作为假肢步态识别信息源,提出了一种基于张量投影特征和 FA-ELM 的步态识别方法,可用于智能下肢假肢的步态识别。实验结果表明,鱼群算法进化 ELM 方法提高了下肢假肢的步态识别准确率,说明了将鱼群算法进化 ELM 方法用于下肢假肢步态识别领域的可行性与正确性。

#### 参 考 文 献

[1] Wen Yue, Jennie S, Gao Xiang. A new powered lower

limb prosthesis control framework based on adaptive dynamic programming[J]. IEEE Transaction on Neural Networks and Learning Systems, 2017, 28(9): 2215-2220.

[2] Ledoux E, Goldfarb M. Control and evaluation of a powered transfemoral prosthesis for stair ascent[J]. IEEE Transaction on Neural Systems and Rehabilitation Engineering, 2017, 25(7): 917-924.

[3] Quintero D, Martin A, Gregg R. Toward unified control of a powered prosthetic leg: A simulation study[J]. IEEE Transaction on Control Systems Technology, 2018, 26(1): 305-311.

[4] Martin A E, Gregg R D. Stable, robust hybrid zero dynamics control of powered lower-limb prostheses [J]. IEEE Transaction on Automatic Control, 2017, 62

- (8): 3930-3942.
- [5] Shultz A H, Goldfarb M. A unified controller for walking on even and uneven terrain with a powered ankle prosthesis[J]. IEEE Transaction on Neural Systems and Rehabilitation Engineering, 2018, 26(4): 788-797.
- [6] Shultz A H, Lawson B E, Goldfarb M. Variable cadence walking and ground adaptive standing with a powered ankle prosthesis[J]. IEEE Transaction on Neural Systems and Rehabilitation Engineering, 2016, 24(4): 495-505.
- [7] Culver S, Bartlett H, Shultz A. A stair ascent and descent controller for a powered ankle prosthesis[J]. IEEE Transaction on Neural Systems and Rehabilitation Engineering, 2018, 26(5): 993-1002.
- [8] 张小栋, 陈江城, 尹贵. 下肢康复机器人肌电感知与人机交互控制方法[J]. 振动、测试与诊断, 2018, 38(4): 649-657.  
Zhang Xiaodong, Chen Jiangcheng, Yin Gui. An approach for human-robot interactive control of lower limb rehabilitation robot based on surface EMG perception[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(4): 649-657. (in Chinese)
- [9] 丁其川, 熊安斌, 赵新刚, 等. 基于表面肌电的运动意图识别方法研究及应用综述[J]. 自动化学报, 2016, 42(1): 13-25.  
Ding Qichuan, Xiong Anbin, Zhao Xingang, et al. A review on researches and applications of sEMG-based motion intent recognition methods [J]. Acta Automatica Sinica, 2016, 42(1): 13-25. (in Chinese)
- [10] 王蕾, 王辉, 黄品高, 等. 下肢截肢者行走意图识别方法研究进展[J]. 自动化学报, 2018, 42(12): 1765-1779.  
Wang Lei, Wang Hui, Huang Pingao, et al. Progress and perspective of studies on recognition methods for walking intention of lower-limb amputees [J]. Acta Automatica Sinica, 2018, 42(12): 1765-1779. (in Chinese)
- [11] 杨义勇, 王人成, 王延利, 等. 新型仿生膝关节的机构设计与仿真研究[J]. 中国机械工程, 2008, 19(1): 72-77.  
Yang Yiyong, Wang Rencheng, Wang Yanli, et al. Humanoid design and movement simulation of a new knee prosthesis [J]. China Mechanical Engineering, 2008, 19(1): 72-77. (in Chinese)
- [12] He Huang, Todd A K. A strategy for identifying locomotion modes using surface electromyography [J]. IEEE Transactions on Biomedical Engineering, 2009, 56(1): 65-73.
- [13] Simon A M, Ingraham K A, Spanias J A. Delaying ambulation mode transition decisions improves accuracy of a flexible control system for powered knee-ankle prosthesis[J]. IEEE Transaction on Neural Systems and Rehabilitation Engineering, 2017, 25(8): 1164-1171.
- [14] Huang S, He Huang. Voluntary control of residual antagonistic muscles in transtibial amputees: feedforward ballistic contractions and implications for direct neural control of powered lower limb prostheses[J]. IEEE Transaction on Neural Systems and Rehabilitation Engineering, 2018, 26(4): 894-903.
- [15] Abel E W, Zacharia P C, Forster A, et al. Neural network analysis of the EMG interference pattern [J]. Medical Engineer and Physics, 1996, 18(1): 12-17.
- [16] 陈玲玲. 肌电信号的运动模式识别及其在膝上假肢中的应用研究[D]. 天津: 河北工业大学, 2010.
- [17] 顾明亮, 刘俊. 改进的 PSO-SVM 在表面肌电信号模式识别中的研究[J]. 传感技术学报, 2017, 30(10): 1459-1464.  
Gu Mingliang, Liu Jun. A support vector machine based on an improved particle swarm optimization algorithm for sEMG signal pattern recognition[J]. Chinese Journal of Sensors and Actuators, 2017, 30(10): 1459-1464. (in Chinese)



**第一作者简介:**刘磊,男,1984年9月生,副教授。主要研究方向为假肢控制、模式识别及智能机器人技术。曾发表《采用核主成分分析和相关向量机的假肢运动意图识别》(《机器人》2017年第39卷第5期)等论文。  
E-mail: liulei20060000@126.com