

基于多核学习极限学习机的助行机器人运动相容性识别^①

刘 磊^② 杨 鹏^③ 刘作军 宋寅卯

(郑州轻工业大学建筑环境工程学院 郑州 450002)

摘 要 下肢外骨骼作为一种可穿戴设备可以保护人体、增强人体的力量、激发人体的自我修复能力,已经在康复领域广泛使用。由于外骨骼机器人实际运动意图与期望运动意图存在一定差异(即运动不相容),容易造成穿戴者不舒适。为了提高运动相容性识别的准确率,本文针对步幅过大、步幅过小、步幅相容采用多核学习极限学习机(ELM)的方法进行了识别。表面肌电信号(sEMG)包含了大量的步态信息,能够很好地应用于运动相容性的识别,首先从时域、频域、时频域等角度提取了表面肌电信号特征,然后利用灰狼算法优化极限学习机核函数参数,最后用多核极限学习机理论,获得最优的分类模型。实验结果表明,基于多核学习极限学习机的助行机器人运动相容性识别准确率较单核极限学习机有明显提高。

关键词 多核学习; 极限学习机(ELM); 表面肌电信号(sEMG); 运动相容性识别

0 引 言

下肢外骨骼助力机器人是一种可为人体下肢行走提供关节助力的装置,其特点在于可以识别各种路况与步速^[1-3]。由于外骨骼机器人实际运动意图与期望运动意图存在一定差异(运动不相容),穿戴者容易摔倒。外骨骼机器人的关节机构与控制方法是目前研究的热点问题,但对外骨骼机器人的运动相容性识别研究不多。当外骨骼机器人的运动轨迹与人体期望运动轨迹不一致时,为实现外骨骼助行机器人可自适应调整,本文对步幅过大、步幅过小及步幅相容 3 种人机运动相容性进行识别。

表面肌电信号(surface electromyography, sEMG)是人体的一种生理信号,能够准确地反映各个肌肉的实时状态^[4]。因此本文选择 sEMG 作为信号源,特征提取和模式识别是其中最重要的两个环节。在众多的 sEMG 特征参数提取方法中,时域特征、频域特征、时频域特征和非线性特征被证明具有良好的

识别能力。

分类器的设计是模式识别领域中非常重要的环节,隐马尔可夫模型、BP(back propagation)神经网络、支持向量机(support vector machine, SVM)、极限学习机(extreme learning machine, ELM)^[5]是目前常用的分类器,基于 ELM 的分类模型,因其实施简单、训练时间短,已在助行机器人运动相容性识别领域取得了较好的识别结果,但是单核特征表达的单一性,限制了模型分类精度的进一步提高。为了解决此问题,本文首先从时域、频域、时频域角度提取了表面肌电信号特征,然后利用灰狼算法优化极限学习机核函数参数,最后用多核极限学习机理论,获得最优的分类模型。实验结果表明,基于多核学习 ELM 的助行机器人运动相容性识别准确率较单核极限学习机有明显提高。

1 极限学习机

极限学习机可以看作是单隐含层网络,内部为

① 国家自然科学基金(61773151, 61703135)资助项目。

② 男,1984 年生,博士,讲师;研究方向:智能假肢与模式识别;E-mail: liulei20060000@126.com

③ 通信作者, E-mail: kongzhi_xueke@163.com

(收稿日期:2020-09-03)

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 和 m , 其结构如图 1 所示。




图 1 极限学习机网络结构

设输入层与隐含层、隐含层与输出层之间的连接权值分别如下:

$$\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_l \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & & \vdots \\ w_{l1} & w_{l2} & \cdots & w_{ln} \end{bmatrix}_{l \times n} \quad (1)$$

$$\mathbf{v} = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_l \end{bmatrix} = \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1m} \\ v_{21} & v_{22} & \cdots & v_{2m} \\ \vdots & \vdots & & \vdots \\ v_{l1} & v_{l2} & \cdots & v_{lm} \end{bmatrix}_{l \times m} \quad (2)$$

隐含层阈值为

$$\mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_l \end{bmatrix} \quad (3)$$

激活函数用 $g(x)$ 表示, 输入样本数目为 N , 则输出 $\mathbf{Y} \in R^{m \times N}$ 可以表示为

$$\mathbf{Y} = \mathbf{H}\mathbf{v} \quad (4)$$

其中 $\mathbf{H}$ 为隐含层输出矩阵。

$\mathbf{H} =$

$$\begin{bmatrix} g(w_1x_1 + b_1) & g(w_2x_1 + b_2) & \cdots & g(w_lx_1 + b_l) \\ g(w_1x_2 + b_1) & g(w_2x_2 + b_2) & \cdots & g(w_lx_2 + b_l) \\ \vdots & \vdots & & \vdots \\ g(w_1x_N + b_1) & g(w_2x_N + b_2) & \cdots & g(w_lx_N + b_l) \end{bmatrix} \quad (5)$$

当 $g(x)$ 无限可微时, ELM 的参数可在训练前任意指定, 且在训练过程中保持不变。输出层权值

$\mathbf{v}$ 由求解下式获得。

$$\min_{\mathbf{v}} \|\mathbf{H}\mathbf{v} - \mathbf{Y}\| \quad (6)$$

式(6)的解为

$$\hat{\mathbf{v}} = \mathbf{H}^+ \mathbf{Y} \quad (7)$$

其中 $\mathbf{H}^+$ 为隐含层输出矩阵 $\mathbf{E}$ 的广义逆矩阵。

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。

2 多核学习极限学习机

假定 n 个样本, 采用 m 个核映射函数 g_i 映射得到 m 个特征值, β_i 表示对应核函数 g_i 的 ELM 输出权重, 多核 ELM^[6-8] 优化公式为

$$\min_{\tau} \min_{\beta} \frac{1}{2} \sum_{p=1}^m \frac{\|\beta_p\|^2 F}{\gamma_p} + \frac{C}{2} \sum_{i=1}^n \|\xi_i\|^2 \quad (8)$$

$$\text{s. t. } \sum_{p=1}^m \beta_p^T g_p(X_i) = y_i - \xi_i, \quad \forall_i \sum_{p=1}^m \gamma_p = 1, \quad \gamma_p \geq 0, \quad \forall_p$$

其中, $\beta = [\beta_1, \beta_2, \dots, \beta_p]$ 表示多个核函数融合矩阵的输出权重, ξ_p 表示第 i 个样本的训练误差, C 表示平衡因子, γ_p 表示第 p 个核函数对应的特征值的融合系数, y_i 表示第 i 个样本标签。

式(8)的拉格朗日乘子方程为

$$\begin{aligned} L(\beta, \xi, \gamma) = & \frac{1}{2} \sum_{p=1}^m \frac{\|\beta_p\|^2 F}{\gamma_p} + \frac{C}{2} \sum_{i=1}^n \|\xi_i\|^2 \\ & - \sum_{i=1}^n \sum_{p=1}^m \alpha_i \left(\sum_{p=1}^m \beta_p^T g_p(x_i) - y_i + \xi_i \right) \\ & + \tau \left(\sum_{p=1}^m \gamma_p - 1 \right) \end{aligned} \quad (9)$$

其中 α 和 τ 表示拉格朗日乘子, 最优结构参数 α 和核融合系数 τ 是多核学习 ELM 的重要参数, 通过式(9)可求解多核 ELM 最优结构参数 α 和核融合系数 τ 。

$$\alpha = \left(\mathbf{K}(\cdot, \cdot) \quad \gamma \right) \frac{\mathbf{I}}{C} \mathbf{Y}^T \quad (10)$$

$$\gamma_p^{new} = \frac{\|\beta_p\|_F}{\sum_{p=1}^m \|\beta_p\|_F}, \quad \forall p \quad (11)$$

其中, $\mathbf{K}(\cdot, \cdot)$ 为多个核函数通过融合系数 τ 融合后的核矩阵, 最后计算输出权重 β_p 。

$$\|\beta_p\|_F = \gamma_p \sqrt{\sum_{s,t=1}^T \sum_{j=1}^n \alpha_{it} \alpha_{js} K_p(x_i, y_j)} \quad (12)$$

3 基于多核学习 ELM 的助行机器人运动相容性识别

3.1 表面肌电信号采集

根据文献[9,10]的研究结果,阔筋膜张肌、股内侧肌、长收肌和股直肌针对下肢运动识别效果较好,能够得到清晰的信号,因此选择这4块肌肉采集sEMG信号。步幅过大、过小和相容3种运动模式的步幅分别为700 mm、350 mm、500 mm。实验对象共6名,实验对象均自愿参加实验并签署了知情同意书,无下肢神经及肌肉骨骼病史,在实验前被告知实验的过程及要求。每位实验对象3种情况各采集100组数据。表面肌电信号采用高精度、高性能的Trigno TMWireless sEMG无线肌电采集系统,图2为sEMG传感器位置图,图3为sEMG信号采集与显示。



图2 传感器位置图




图3 信号采集与显示

3.2 信号预处理与特征提取

本文选择巴特沃斯滤波器对信号预处理。肌电信号特征值的提取是运动相容性识别的关键环节,本文采用时域特征提取法、频域特征提取法、肌电信号非线性特征提取法及小波包特征提取法^[11],每名受试者的3种运动状态都截取512个数据点分析。小波包特征提取方法如下:参考移动窗采样方法,移动窗大小为64点,每采集256点后进行一次小波包分解,将4块肌肉表面肌电信号作4层db2小波包分解,提取2⁴个频带的信号并计算各频带信号能量作为特征值。排列组合熵主要是用来度量sEMG的复杂度和非线性,通过使用排列组合熵可以评估和分析信号时间序列所呈现的一定规律性。本文选择排列组合熵表示sEMG非线性特征,计算过程参考文献[12]的方法。表1给出了特征值的基本意义,表2给出了特征值的具体内容。

表1 特征属性的基本意义

属性	基本意义
方差	用来衡量变量的离散程度
均方根	代表信号幅值的统计量
过零点数	反映信号的频次信息
波长	反映信号的振幅信息
中值频率	统计表面肌电信号频段分布中心点的情况
中位频率	在一定程度上表示每个步态阶段中的稳态过程的特征信息
小波包能量	小波包分解能够对信号在低频和高频段同时进行
排列组合熵	排列组合熵通过对相邻数据之间的比较来度量肌电信号的复杂度

表2 肌电信号特征

特征类别	特征属性
时域特征	方差、均方根、过零点数、波长
频域特征	中值频率、中位频率
时频域特征	小波包能量
非线性特征	排列组合熵

3.3 核函数的选择

ELM分类器需要选择核函数,线性核函数、多项式核函数、高斯核函数和Sigmoid核函数是目前

广泛使用的核函数。

线性核函数:

$$k(x, x') = xx' \quad (13)$$

多项式核函数:

$$k(x, x') = (xx' + 1)^{q_1} \quad (14)$$

高斯核函数:

$$k(x, x') = \exp(-(x - x')(x - x')'/2q_2^2) \quad (15)$$

Sigmoid 核函数:

$$k(x, x') = \tanh(q_3xx' + q_4) \quad (16)$$

本文将对表 2 中时域特征、频域特征、时频域等特征选用不同的核函数得到识别结果,通过分析对比来选择最优核函数。

3.4 核参数选择

多核学习 ELM 参数确定的过程相对简单,核函数参数是影响识别结果的重要参数,本文采用灰狼优化算法对核参数进行寻优。

灰狼算法是基于对自然界灰狼群的社会等级制度和围猎行为的模拟^[13-14]。在 D 维搜索空间中,定义种群 $X = \{X_1, X_2, \dots, X_n\}$, 其中 n 表示种群中灰狼的个体数。定义 $X_i = \{X_i^1, X_i^2, \dots, X_i^d\}$ 表示第 i 只灰狼的位置,其中 X_i^d 表示第 i 只灰狼在第 d 维上的位置。将在遍历种群的当前最优解记为 α , 将适应度当前排名次优的解记为 β , 将适应度当前排名第 3 的解记为 δ , 种群中的其他个体记为 ω , 猎物的位置即为优化问题的全局最优解。

在围猎过程中,狼群根据下式对猎物进行包围:

$$D = |CX_p(t) - X(t)| \quad (17)$$

式中, $X_p(t)$ 表示种群迭代至第 t 代时猎物的位置; $X(t)$ 表示第 t 代灰狼个体的位置;常数 C 表示摆动因子。

$$C = 2r_1 \quad (18)$$

其中, $r_1 = \text{rand}(0, 1)$ 。

根据下式更新灰狼个体的位置:

$$X(t+1) = \dot{X}_p(t) - AD \quad (19)$$

其中, A 表示收敛因子。

$$A = \alpha(2r_2 - 1) \quad (20)$$

其中, α 随着迭代次数的增加,从 2 递减至 0, $r_2 = \text{rand}(0, 1)$ 。

在狼群中, α 、 β 、 δ 最靠近猎物,灰狼优化算法利用 3 个个体来确定是否为最优解。在灰狼群中,个体围杀猎物行为的数学描述如下。

计算在第 t 代时, α 、 β 、 δ 对种群内灰狼个体位置的影响 X_1 、 X_2 、 X_3 , 如下:

$$D_\alpha = |C_1X_\alpha(t) - X(t)| \quad (21)$$

$$D_\beta = |C_2X_\beta(t) - X(t)| \quad (22)$$

$$D_\delta = |C_3X_\delta(t) - X(t)| \quad (23)$$

$$X_1 = X_\alpha(t) - A_1D_\alpha \quad (24)$$

$$X_2 = X_\beta(t) - A_2D_\beta \quad (25)$$

$$X_3 = X_\delta(t) - A_3D_\delta \quad (26)$$

式中, $X_\alpha(t)$ 、 $X_\beta(t)$ 、 $X_\delta(t)$ 表示种群迭代至第 t 代时 α 、 β 、 δ 的位置, $X(t)$ 表示第 t 代灰狼个体的位置, C_1 、 C_2 、 C_3 和 A_1 、 A_2 、 A_3 表示不同的摆动因子与收敛因子。

根据式(27)计算第 t 轮迭代后种群内个体的新位置。

$$X(t+1) = (X_1 + X_2 + X_3)/3 \quad (27)$$

3.5 基于多核学习 ELM 运动相容性识别流程

利用多核学习 ELM 进行运动相容性识别具体步骤如下。

(1) 采集 6 名实验对象 3 种运动模式下的 sEMG。

(2) 利用巴特沃斯带通滤波器对 sEMG 滤波处理,并将处理后数据的 50% 选为训练样本、50% 选为测试样本。

(3) 采用 3.2 节方法对预处理后的 sEMG 从不同角度进行特征提取。

(4) 构建多核学习 ELM 分类模型,利用灰狼算法寻找分类器中最优核函数参数。

(5) 利用训练样本训练多核学习 ELM 分类器的性能,利用测试样本检验训练效果,得出识别结果。

识别流程如图 4 所示。

3.6 实验结果分析

本文按照 3.1 节方法采集 sEMG,利用巴特沃斯带通滤波消除因零点漂移所产生的基线。图 5 为步幅过大、过小、相容时长收肌信号图。图 6 为步幅过大不相容运动模式中股内侧肌原始 sEMG、巴特

沃斯滤波 sEMG、整流 sEMG 波形对比。







图 4 算法流程图



(a) 步幅过大长收肌信号图




(b) 步幅过小长收肌信号图




(c) 步幅相容长收肌信号图


图 5 步幅过大、过小、相容长收肌信号图



(a) 原始股内侧肌信号图



(b) 滤波后股内侧肌信号图



(c) 整流后股内侧肌信号图

图 6 整流前后股内侧肌波形对比

对每组数据分别提取 4 种 sEMG 特征参数,分别是时域特征、频域特征、灰度矩特征和小波域特征,按照式(28)对特征参数进行归一化处理。

$$x_{\text{new}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (28)$$

其中, x 、 x_{new} 分别表示归一化前后的数据, $x_{\max}$ 和

$x_{\min}$ 分别表示数据的最大值和最小值。

由表 3 可见,时域特征的最佳核函数是高斯核函数;时频域特征的最佳核函数是高斯核函数;频域特征的最佳核函数为 Sigmoid 核函数;非线性特征的最佳核函数为多项式核函数。利用最优核函数组合多核核函数,表 4 给出了最优核组合。

表 3 单核 ELM 识别结果

特征	识别准确率/%			
	线性	多项式	高斯	Sigmoid
时域特征	93.4	93.6	98.5	88.7
频域特征	83.8	91.2	91.9	93.5
时频域特征	91.9	93.7	96.3	93.8
非线性特征	94.0	94.1	93.6	91.5

表 4 最优核函数组合

不同类型特征值	最优核函数
时域特征	高斯核函数
频域特征	Sigmoid 核函数
时频域特征	高斯核函数
非线性特征	多项式核函数

根据表 4 的最优组合构造多核 ELM 分类模型,并对参数利用灰狼算法寻找最优核函数参数。灰狼算法参数设置如下,初始种群规模为 30,最大迭代次数为 300,维度为 20,运行次数为 20,灰狼算法中的反向学习优化选择概率 $p = 0.5$ 。采用 5 折交叉验证的识别准确率作为适应度函数。经过 20 次计算求均值,表 5 给出了最优核函数参数。将参数优化之后的多核学习 ELM 分类器应用于测试样本,结果如图 7 所示。可以看出,4 种单核 ELM 用于不同特征参数的运动相容性模式识别时,识别准确率差异很大,即单一核函数应用于不同特征空间时,无法

表 5 最优核函数参数

不同类型特征值	最优核函数参数
时域特征	$p2 = 1.85$
频域特征	$p3 = 3.47, p4 = 5.06$
时频域特征	$p2 = 3.62$
非线性特征	—




图 7 不同 ELM 核函数与多核学习 ELM 对比实验结果

保证稳定的高识别率;而多核学习 ELM 不但保证了在每个特征空间提供最优识别率,而且在时频域特征空间中把识别正确率从 92.6% 提高 94.7%。

本文运用 SVM、多核学习 SVM、ELM、多核学习 ELM 4 种识别方法进行运动相容性识别。为了更好地比较 4 种方法的识别结果,选择了 Matlab 中的方差分析 (analysis of variance, ANOVA) 的统计学方法进行分析,显著性系数选择均为 $P = 0.05$ 。

首先对 6 位实验对象基于多核学习 SVM、SVM、ELM、多核学习 ELM 4 种识别方法的识别结果进行比较。图 8 给出基于 SVM、多核学习 SVM、ELM、多核学习 ELM 平均识别准确率分别为 $87.00\% \pm 3.66\%$ 、 $89.66\% \pm 3.58\%$ 、 $91.37\% \pm 4.31\%$ 、 94.37%




图 8 4 种方法对比实验结果

$\pm 4.31\%$ 。经 ANOVA 分析发现,无论是 SVM 还是多核 SVM 均与多核学习 ELM 方法存在显著性差异 ($P < 0.01$),可以看出多核学习 ELM 模式识别方法比 SVM、多核学习 SVM 模式识别方法更适合相容性识别。对于 ELM 与多核学习 ELM 的识别结果进行 ANOVA 分析发现并无显著性差别 ($P = 0.9517$),从实验结果来看,多核学习 ELM 要略优于 ELM 方法。

为了更清晰地分析不同方法的准确率差异性,将 6 位实验对象的每一类运动的识别准确率进行统计平均,得到结果如表 6 所示。从表 6 中可以看出,仅对步幅过大的情况基于 ELM 识别方法的准确率略高于多核学习 ELM 方法,对于步幅过小、步幅相容情况多核学习 ELM 方法均有明显的优势,对于助行机器人运动相容性识别来说,多核学习 ELM 方法性能更好。

表 6 不同方法每一类运动的识别准确率

	步幅过小/%	步幅过大/%	步幅相容/%
SVM	87.22	89.36	85.91
多核学习 SVM	91.58	87.83	89.62
ELM	90.54	92.27	91.09
多核学习 ELM	94.07	91.85	97.16

4 结 论

本文研究了一种基于多核学习 ELM 的助行机器人运动相容性识别方法,把采集到的 4 个特征空间的特征数据作为分析对象进行助行机器人运动相容性识别研究,得出以下结论。

(1)多核学习 ELM 融合了多种 sEMG 特征,能够较为全面地描述运动信息。

(2)多核学习 ELM 分类器针对每个运动特征空间分别选取最优核函数,并利用灰狼算法实现了核参数的优化配置。

(3)实验结果表明,多核学习 ELM 分类器可以通过不同核函数融合任意多组运动特征信息,识别准确率优于 ELM 和单核 SVM,具有较好的实用性和推广性。

参考文献

- [1] 丁其川,赵新刚,韩建达. 基于肌电信号容错分类的手部动作识别[J]. 机器人,2015,37(1):9-16
- [2] 陈江城,张小栋,李睿. 利用表面肌电信号的下肢动态关节力矩预测模型[J]. 西安交通大学学报,2015,49(12):26-33
- [3] 陶永,王田苗,刘辉,等. 智能机器人研究现状及发展趋势的思考与建议[J]. 高技术通讯,2019,29(2):149-163
- [4] 高云园,孟明,罗志增,等. 利用多源运动信息的下肢假肢多模式多步态识别研究[J]. 传感器技术学报,2011,24(11):1574-1578
- [5] 周晓,李永清,张有兵. 基于 ELM 的非侵入式电力负荷识别算法[J]. 高技术通讯,2020,30(10):1018-1024
- [6] 孙涛,冯婕. 快速随机多核学习分类算法[J]. 西安电子科技大学学报,2016,43(1):36-40
- [7] 高巍,彭宇. 基于马氏距离多核学习的高光谱图像分类[J]. 仪器仪表学报,2018,39(3):250-257
- [8] 余家林,孙季丰,李万益. 基于多核稀疏编码的三维人体姿态估计[J]. 电子学报,2016,44(8):1899-1908
- [9] Huang S, Huang H. Voluntary control of residual antagonistic muscles in transtibial amputees: feed forward 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
- [10] Huang H, Zhang F, Hargrove L J, et al. Continuous locomotion-mode identification for prosthetic legs based on neuromuscular-mechanical fusion[J]. *IEEE Transactions on Biomedical Engineering*,2011,58(10):2867-2875
- [11] 王蕾,王辉,黄品高. 下肢截肢者行走意图识别方法研究进展[J]. 自动化学报,2015,44(8):1370-1380
- [12] 席旭刚,武昊,左静. 基于排列组合熵和加权核 Fisher 的肌电跌倒检测[J]. 上海交通大学学报,2015,49(11):1685-1700
- [13] 廖小平,黎宇嘉,陈超逸. 基于核主成分和灰狼算法的刀具磨损状态识别[J]. 计算机集成制造系统,2019,44(8):1-15
- [14] 傅蔚阳,刘以安,薛松. 基于灰狼算法与小波神经网络的目标威胁评估[J]. 浙江大学学报,2018,52(4):680-686

Motion compatibility recognition of walking robot based on multi-core learning limit learning machine

Liu Lei, Yang Peng, Liu Zuojun, Song Yinmao

(School of Building Environmental Engineering, Zhengzhou University of Light Industry, Zhengzhou 450002)

Abstract

Lower limb exoskeleton as a wearable device can protect the human body, strengthen the power of human body, and stimulate the body's ability to repair itself. It has been widely used in the field of rehabilitation. Because the robot motion intention and actual expected intention of the exoskeleton robot exist certain differences (incompatible), it is easy to cause uncomfortable of the wearers. In order to improve the recognition accuracy of motion compatibility, a method of multi-core learning extreme learning machine (ELM) is used for large stride length, small stride length, and compatible stride length. Surface electromyography (sEMG) signal contains a large amount of gait information, which is applied to the recognition of motion compatibility. Firstly, the features of sEMG signals are extracted from time domain, frequency domain, and time frequency domain. Then, the extreme learning machine kernel function parameters are optimized by the gray wolf algorithm with multi-core extreme learning machine theory. Finally, the optimal classification model is obtained by using multi-core learning extreme learning machine theory. The experimental results show that the recognition accuracy based on multi-core learning extreme learning machine of walking robot motion compatibility recognition is better than extreme learning machine.

Key words: multi-core learning, extreme learning machine (ELM), surface electromyography (sEMG), motion-compatibility recognition