

基于气压肌动图和改进神经模糊推理系统的手势识别研究

汪雷¹ 黄剑¹ 段涛¹ 伍冬睿¹ 熊蔡华² 崔雨琦¹

摘要 手势识别是人机交互领域的重要研究内容,为截肢患者控制智能假手提供基础。当前主流方法之一是利用表面肌电图 (Electromyogram, EMG) 识别手部运动意图,但肌电信号存在信号弱和易受噪声、汗液、疲劳影响等缺点。同时肌电图在识别准确率方面,尤其是截肢患者手势识别方面仍然具有较大的提升空间。针对这些问题,设计了基于气压肌动图 (Pressure-based mechanomyogram, pMMG) 的穿戴式信号采集装置,为手势识别提供了优质的信号源。结合深度神经网络中全连接层结构、典型抽样和标准正则化技术,提出了一种改进多类神经模糊推理系统 (Improved multicalss neural fuzzy inference system, IMNFIS),与传统自适应神经模糊推理系统 (Adaptive neural fuzzy inference system, ANFIS) 相比,泛化能力得到显著提升。招募了 7 名健康受试者和 1 名截肢受试者,并用 8 种算法开展离线实验。所提方法在残疾人手势识别实验中取得了 97.25% 的最高平均准确率,在健康人手势识别实验中取得了 98.18% 的最高平均准确率。与近年公开报道的多种手势识别研究相比,所提方法的综合性能更优。

关键词 手势识别,肌动图,神经模糊推理系统,自适应学习算法

引用格式 汪雷,黄剑,段涛,伍冬睿,熊蔡华,崔雨琦.基于气压肌动图和改进神经模糊推理系统的手势识别研究.自动化学报,2022,48(5):1220-1233

DOI 10.16383/j.aas.c200901

Research on Gesture Recognition Based on Pressure-based Mechanomyogram and Improved Neural Fuzzy Inference System

WANG Lei¹ HUANG Jian¹ DUAN Tao¹ WU Dong-Rui¹ XIONG Cai-Hua² CUI Yu-Qi¹

Abstract Gesture recognition, which provides a foundation for amputees to control smart prosthetic hands, is an important research content in the field of human-robot interaction. One of the current mainstream methods is using surface electromyogram (EMG) to identify the intention of hand motion, while EMG signals are weak and show some shortages of being interfered easily by noise, sweat, fatigue, etc. At the same time, there is still large room for the improvement in the recognition accuracy, especially in the gesture recognition of amputees by using EMG. To solve these problems, a wearable signal acquisition device based on pressure-based mechanomyogram (pMMG) is designed in this paper, which provides a signal source of high quality for gesture recognition. We proposed an improved multicalss neural fuzzy inference system (IMNFIS) by combining the full connection layer structure, typical sampling and uniformed regularization techniques in deep neural network, which significantly improved the generalization ability compared with the traditional adaptive neural fuzzy inference system (ANFIS). We recruited seven healthy subjects and an amputee subject, and then conducted an offline experiment in which eight algorithms are used. The proposed method got the highest average accuracy of 97.25% in the experiment of the disabled, and 98.18% in the experiment of the healthy. Compared with many reported gesture recognition researches in recent years, the method proposed in this paper achieves the better comprehensive performance.

Key words Gesture recognition, mechanomyogram (MMG), neural fuzzy inference system, adaptive learning algorithm

Citation Wang Lei, Huang Jian, Duan Tao, Wu Dong-Rui, Xiong Cai-Hua, Cui Yu-Qi. Research on gesture recognition based on pressure-based mechanomyogram and improved neural fuzzy inference system. *Acta Automatica Sinica*, 2022, 48(5): 1220-1233

收稿日期 2020-10-27 录用日期 2021-03-02

Manuscript received October 27, 2020; accepted March 2, 2021

国家自然科学基金联合基金重点支持项目 (U1913207), 湖北省技术创新专项 (2019AEA171), 科技部政府间国际科技创新合作重点专项 (2017YFE0128300) 资助

Supported by National Natural Science Foundation of China (U1913207), Technology Innovation Project of Hubei Province (2019AEA171), and International Science and Technology Cooperation Program of China (2017YFE0128300)

本文责任编辑 郑伟诗

Recommended by Associate Editor ZHENG Wei-Shi

1. 华中科技大学人工智能与自动化学院图像信息处理与智能控制教育部重点实验室 武汉 430074 2. 华中科技大学机械科学与

手势作为一种自然、有效的交流方式,在人机交互的应用中发挥着重要的作用^[1],并已成为操纵人机接口的主流方法之一^[2]。对于手部截肢患者等

工程学院数字制造装备与技术国家重点实验室 武汉 430074

1. Ministry of Education Key Laboratory on Image Information Processing and Intelligent Control, School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074 2. State Key Laboratory of Manufacturing Equipment and Technology, School of Mechanical Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074

在运动控制和运动功能方面有困难的残障人群, 基于手势识别技术的人机接口及其应用有助于通过智能假肢恢复他们缺失的自然手部功能, 因而相关研究对于此类弱势群体而言至关重要。

当前, 基于穿戴式生物信号采集装置的手势识别研究大多利用肌电图 (Electromyogram, EMG) 实现^[3-6]。由于 EMG 信号通常比较微弱 (亚毫伏级别), 因而存在对于电噪声敏感、需要笨重的滤波放大电路等外围设备、不可重复等缺点。此外, 肌肉通常在皮肤下交错以肌肉群的方式出现, 且在获取 EMG 信号时, 传感器必须直接附着在皮肤上甚至侵入皮肤, 所以 EMG 也存在串扰、易受汗液和肌肉疲劳影响等缺陷。近年来, 肌动图 (Mechanomyogram, MMG) 逐渐受到科研人员的重视^[7-11], 它具有信号强、采集方便、非侵入等优点, 更重要的是 MMG 对于出汗、电噪声等不利影响有很好的鲁棒性。此外, MMG 与肌力呈近似线性关系, 这种线性关系受肌肉疲劳影响很小^[12]。这些优点使得 MMG 可为人机交互提供优质的信号来源。然而, 截至目前国内利用肌动图信号进行手势识别, 特别是识别截肢者手势并用于假肢手控制的相关研究尚不多见。

从方法上来看, 设计分类能力强和具有学习能力的智能模式识别方法仍是这一领域的主要研究方向。一些典型的研究工作包括基于人工神经网络^[13-14]和基于模糊系统^[15-16]的手势识别方法等。自适应神经模糊推理系统 (Adaptive neural fuzzy inference system, ANFIS) 由于具备模糊系统的可解释性和神经网络的学习性优点, 在处理非线性问题上有很好的效果, 也是手势识别领域潜在的有效工具之一^[17-18]。但传统 ANFIS 只有一个输出节点, 通常适合于解决二分类问题, 在解决多分类问题时存在泛化性能差、训练速度慢等缺点。如何提高 ANFIS 的学习效率和分类精度, 是其应用于手势识别领域亟待解决的难点问题。

考虑到在获取 MMG 时一般会用到加速度计和麦克风, 这两种传感器仅适用于实验室环境, 而基于气压肌动图 (Pressure-based mechanomyogram, pMMG) 能够很好地解决适用范围的问题, 本文采用 pMMG 作为健康人和残疾人手势识别研究的信号来源, 设计了基于气压肌动图的穿戴式信号采集装置。同时针对多分类问题中 ANFIS 存在训练效率低的问题, 提出了一种高效的多分类自适应神经模糊推理系统 (Multi-classification adaptive neural fuzzy inference system, MC_ANFIS), 其特点在于仅需要训练一个 MC_ANFIS, 就可以完成对于多种手势的分类任务, 用以实现多手势分

类中分类器的高效训练。

本文的主要工作归纳如下: 1) 通过拓展传统 Takagi-Sugeuo-Kang (TSK) 模糊系统的解模糊层, 提出了一种适用于多分类任务的神经模糊推理系统, 该系统具有很高的训练效率和快速的分类速度; 提出了一种新的高性能自适应多分类算法 MC_TS_UR (Multi-class with typical sampling and uniform regularization), 用改进的抽样方法和正则化技术又极大地提升了所提系统的训练效率, 解决了传统 ANFIS 泛化能力差的问题; 2) 设计了穿戴式气压肌动图信号采集装置, 开展了健康人和残疾人两类受试者的手势识别实验, 与经典的机器学习算法以及近期相关研究结果进行性能对比, 验证了所提系统和方法的有效性。

1 基于气压肌动图的手势数据采集

本节主要叙述 pMMG 原理, 手势数据的采集方法, 预处理和特征提取方法。

1.1 气压肌动图原理

如图 1(a) 所示, 将肌肉看作横截面积 A_m 、长为 x_m 的均匀圆柱体。记初始横截面积为 A_{m0} , 长为 x_{m0} , 假定肌肉总体积 V_{m0} 不变。

Hill 提出的肌肉生物力学方程如下^[19]:

$$(F + a) \cdot (v + b) = (F_0 + a) \cdot b \quad (1)$$

其中, F 为肌力, v 为肌肉收缩速度, a 、 b 和 F_0 均为与肌肉相关的常量, 且 $a \ll F$ 、 $b \ll v$ 。由式 (1) 可得, 在肌肉活动过程中, 即肌肉收缩速度 $v \neq 0$ 时, F 与 v 近似反比, 记比例系数为 k 。肌肉激活时, 长度变化量为 dx_m , 则肌力计算如下:

$$F = k \frac{1}{v} = k \left(\frac{dx_m}{dt} \right)^{-1} \quad (2)$$

如图 1(b) 所示, 假定气囊将肌肉表面全覆盖, 且被臂环固定, 则气囊与肌肉的总横截面积不变。气囊横截面积为 A_b , 气压为 P_b 。记气囊初始横截面积为 A_{b0} , 初始气压为 P_{b0} 。肌肉激活时, 气囊横截面积变化 dA_b , 气压变化 dP_b , 肌肉横截面积变化 dA_m 。假定气囊长度为 l_{b0} 不变, 则由气囊的理想气体方程、肌肉体积和气囊与肌肉总横截面积不变的假设可得:

$$P_{b0}A_{b0} = (P_{b0} + dP_b)(A_{b0} + dA_b) = \frac{nR_bT}{l_{b0}} \quad (3)$$

$$A_{m0}x_{m0} = (A_{m0} + dA_m)(x_{m0} + dx_m) = V_{m0} \quad (4)$$

$$dA_b + dA_m = 0 \quad (5)$$

其中, n 仅与气囊的初始状态有关, R_b 为常量, T




图 1 pMMG 原理图

Fig. 1 The schematic diagram of pMMG

为气体温度. 忽略气体温度变化, 则式 (3) 右边为仅与气囊初始状态有关的常量. 化简式 (3)、式 (4) 并代入式 (5) 可得:

$$dx_m = -\frac{A_{b0}x_{m0}}{P_{b0}A_{m0}}dP_b \quad (6)$$

两边同时对时间求微分, 易得:

$$\frac{dx_m}{dt} = -\frac{A_{b0}x_{m0}}{P_{b0}A_{m0}}\frac{dP_b}{dt} = v \quad (7)$$

将式 (7) 代入式 (2) 可得肌力 F 的计算公式如下:

$$F = -\frac{kA_{m0}P_{b0}}{x_{m0}A_{b0}} \cdot \left(\frac{dP_b}{dt}\right)^{-1} \quad (8)$$

由式 (8) 可以看出, 在肌肉运动过程中, 肌力

与气囊气压变化率 $\frac{dP_b}{dt}$ 有关, 即能够用气压的变化率表征肌肉运动情况. 更进一步, 从式 (8) 中可以得到如下信息:

1) 根据前面提出的假设, k 为与个体相关的变量, A_{b0} 、 x_{m0} 、 V_{m0} 、 P_{b0} 均为与气囊初始状态有关的常量, 所以对于特定个体, $kA_{m0}P_{b0}/(x_{m0}A_{b0})$ 也为常量. 即肌力与气囊气压变化率的倒数线性相关, 且系数仅与装置的初始情况有关.

2) 肌力与气压变化率呈静态关系, 所以知道气压变化率之后, 可立即推算出肌力的大小.

3) 不需要对信号作进一步处理即可得到肌肉活动信息, 与肌电图方法相比更加简洁直观, 且不用担心复杂的滤波、特征提取过程带来的迟滞效应.

注意到虽然式 (8) 给出了肌力和气压之间的量化关系, 表明 pMMG 具有和 EMG 类似的功能, 但是手势和肌力或气压之间的关系却并不明确, 因此仍需研究智能的非线性分类器实现基于 pMMG 的手势识别.

1.2 气压肌动信号采集


本文招募了 7 名上肢健全和 1 名上肢残疾的受试者 (表 1 给出了每名受试者的信息), 设计了如图 2(a) 所示的硬件装置记录每名受试者前臂运动过程中的气压肌动信号. 该装置主要由 6 个单向气囊、6 个 200 kHz 采样频率气压传感器、1 个 GY953 惯性测量单元 (Inertial measurement unit, IMU)、1 对蓝牙收发装置以及 2 条低成本臂环组成. 气压传感器测量手部运动中的 pMMG 信号, 同时 IMU 传感器测量前臂的姿态信号 (返回欧拉角数据), 主要用于补偿手臂位姿带来的气压肌动图差异. 尽管气压传感器的采样频率很高, 但是受限于 IMU 和蓝牙的传输速率, 该硬件装置的采样频率为 200 Hz.

pMMG 手势数据的获取流程如下. 受试者首先按照图 2(b) 所示佩戴好装置, 然后按照以下范式采集手势数据. 先休息 2 s, 接着以 10 s 为周期做每次

表 1 参与手势识别实验的受试者信息

Table 1 Information of the subjects participating in the gesture recognition experiment

受试者	性别	年龄	身高 (cm)	体重 (kg)	腕围 (cm)	健康状况
Subject-1	男	25	180.4	72.4	18.8	健康
Subject-2	男	24	169.5	58.5	16.5	健康
Subject-3	男	56	164.6	61.2	15.8	手部截肢
Subject-4	男	25	172.3	62.8	17.9	健康
Subject-5	男	22	177.5	57.0	16.8	健康
Subject-6	男	26	166.6	65.7	18.4	健康
Subject-7	男	23	170.1	73.3	19.1	健康
Subject-8	男	25	175.5	66.9	17.1	健康



(a) 记录手势数据的装置
(a) The device that records gesture data



(b) 装置的佩戴位置
(b) The position where the device is worn

图 2 手势识别装置及其佩戴位置

Fig.2 The gesture recognition device and it's wearing position

运动, 首先以最大的力量执行屈腕 (Wrist flexion, WF) 手势, 保持 6 s 后休息 4 s, 每种手势运动重复 5 次; 然后按照保持 6 s, 休息 4 s 的规律依次执行伸腕 (Wrist extension, WE)、伸掌 (Hand open, HO)、握拳 (Hand close, HC)、尺侧倾 (Ulnar deviation, UD)、桡侧倾 (Radial deviation, RD), 每完成 6 种手势的运动记为一轮. 每一轮手势数据采集过程如图 3 所示, 每名受试者重复采集 8 轮数据. 对于每一个手势周期, 休息期间的手势数据没有被记录下来, 每种手势的样本数基本相等.

残疾人受试者也依据以上相同范式进行数据采集, 和健康受试者不同的是, 实验过程中他需要在研究人员的指导和帮助下, 注视镜子中的健手做 6 种手势运动, 同时想象残肢和镜像健手做同样的手势运动. 在此过程中, 残肢在运动想象的带动下将会有相应的肌肉运动, 这些运动信息可以被手势识别装置实时记录.

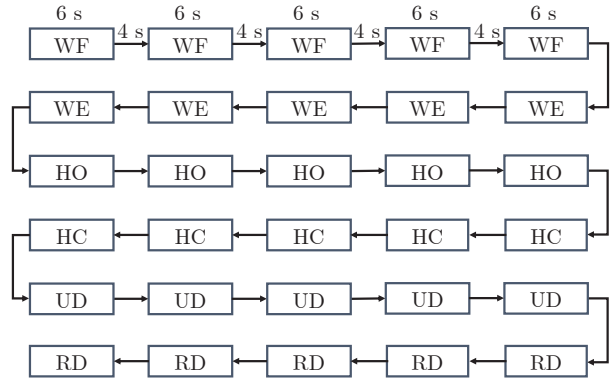


图 3 每一轮的手势数据采集过程
Fig.3 Each round of gesture data acquisition process

该装置检测的是气囊接触位置的气压大小, 所以对于受试者手腕的干湿程度、清洁程度没有要求.

图 4 给出了 6 种手势对应的 pMMG 原始信号图 (Subject-4), 相对于 EMG 信号而言, pMMG 原始信号更加光滑且具有更高的幅值, 对电噪声具有较强的鲁棒性.

1.3 预处理和特征提取

尽管文献 [20] 指出, 与随机和高度可变的表面肌电信号不同, 肌动图与肌力图 (Force myogram, FMG) 通过机械过程自然过滤, 可以将原始压力传感器信号直接用作分类特征. 然而, 第 1.1 节中得到的肌力与气压变化率的关系仅为理想状况下的近似. 实际上前臂肌肉之间的联系非常复杂, 而且存在不同程度的相互干扰. 因此, 仍然有必要对获取的 pMMG 数据作相应的预处理.

由于所使用的 MC_ANFIS 的结构中规则数与输入维度的指数线性相关, 为避免计算冗余, 对采集到的手势数据作降维处理很有必要.

采集到全部的手势数据后, 先将原始值作为原始特征, 离线打上标签后备用. 记手势数据集为 $X = \{\mathbf{x}_i\}_{i=1}^{N_0}$, 其中 $\mathbf{x}_i = (x_1^{(i)}, x_2^{(i)}, \dots, x_9^{(i)})$ 为传感器每次返回的手势数据, $\{x_1^{(i)}, x_2^{(i)}, \dots, x_6^{(i)}\}$ 为 6 通道 pMMG 数据, $\{x_7^{(i)}, x_8^{(i)}, x_9^{(i)}\}$ 为 IMU 返回的一组欧拉角数据, N_0 为采集的手势数据总数. 由实验范式确定手势数据对应的标签, \mathbf{x}_i 标签记为 t_i .

接着对 X 作 z 标准化, 去除掉整个手势数据集自身的偏差. 标准化后的手势数据集记为 $Z = \{\mathbf{z}_i\}_{i=1}^{N_0}$, Z 由公式 $(X - \mu(X))/\sigma(X)$ 计算得到, 其中 $\mu(X)$ 为 X 的均值, $\sigma(X)$ 为 X 的标准差. $\mathbf{z}_i = (z_1^{(i)}, z_2^{(i)}, \dots, z_9^{(i)})$ 为第 i 个原始特征向量.

然后对标准化后的数据集 Z 用主成分分析 (Principal component analysis, PCA) 作降维处理, 选取最大的 M 个特征值之和占协方差矩阵特征值总和 98% 以上的特征向量作为降维后的特征向量.

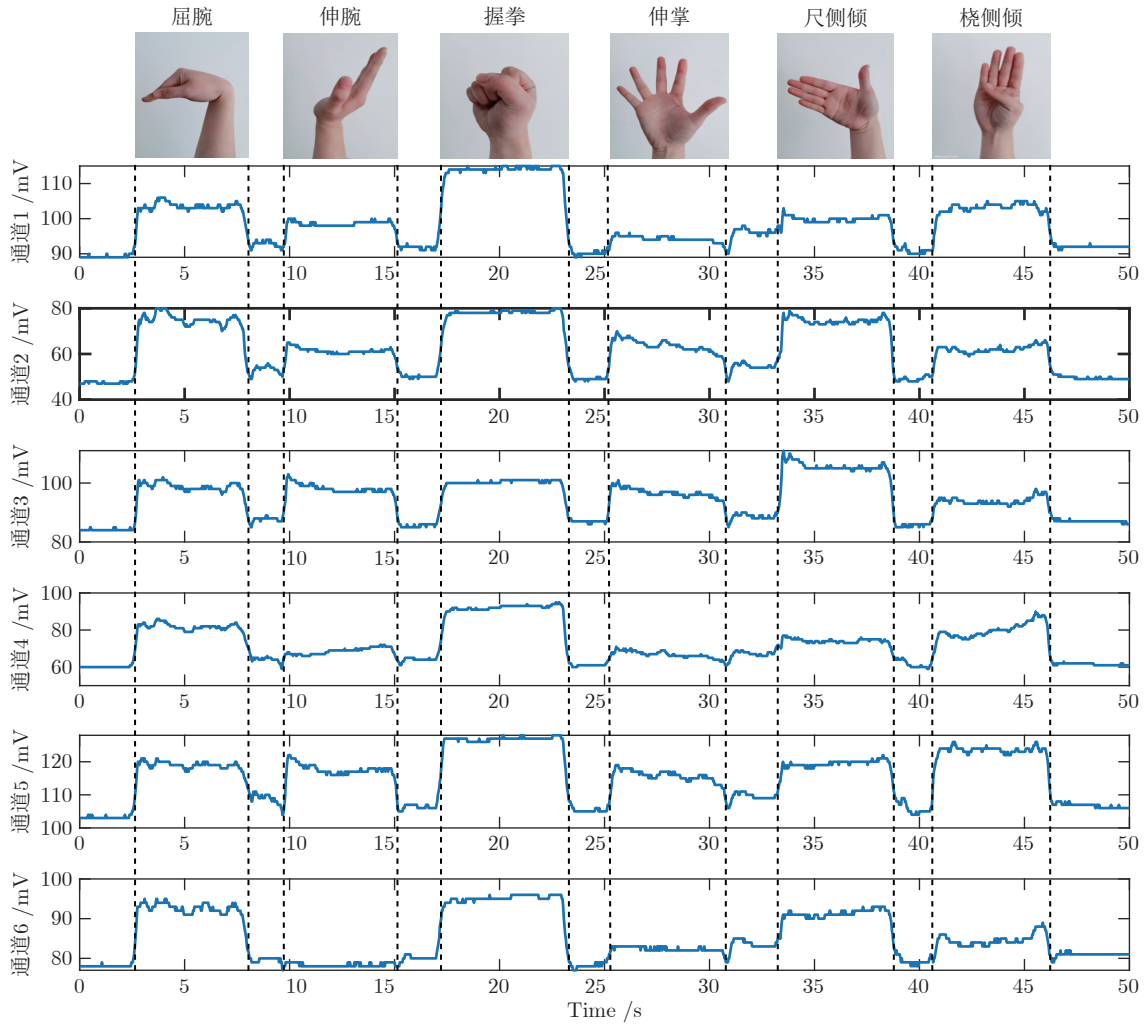


图 4 采集的原始手势数据流

Fig.4 The collected raw gesture data stream

记 Z 特征变换矩阵为 A , z_i 线性变换后的特征向量为 $\zeta_i = z_i A^T = (\zeta_1^{(i)}, \zeta_2^{(i)}, \dots, \zeta_9^{(i)})$, A 的特征向量为 $\{\alpha_i\}_{i=1}^9$, 特征值为 $\{v_i\}_{i=1}^9$. 则选取最小的 M , 使得 $\sum_{i=1}^M (v_i) / \sum_{i=1}^9 (v_i) > 98\%$. 即 PCA 降维后的数据集为 $\zeta = \{\tilde{\zeta}_i\}_{i=1}^{N_0}$, 其中 $\tilde{\zeta}_i = (\zeta_1^{(i)}, \zeta_2^{(i)}, \dots, \zeta_M^{(i)})$. 这样在降低特征维度的同时, 最大限度地保留了原数据集的特征信息.

最后将降维处理后的手势数据随机分为训练集 (80%) 和测试集 (20%). PCA 处理后的手势数据作为降维特征用于 MC_ANFIS 的训练. 数据处理过程如图 5 所示.

2 改进的多类神经模糊推理系统

传统 ANFIS 的单个输出节点适合解决二分类问题, 在解决多分类任务时需要根据类别数设计分类策略、训练多个分类器, 因而训练效率较低, 且包含了 ANFIS 泛化性能较差的缺陷. 针对以上问题,




图 5 手势数据处理过程

Fig.5 Gesture data processing

本节首先构造一种多分类的 ANFIS, 然后又提出一种高性能学习算法 MC_TS_UR 解决其泛化性能较差的问题. 改进的多类神经模糊推理系统 (Improved multicalss neural fuzzy inference system, IMNFIS) 是两者结合的高性能多分类系统.

2.1 MC_ANFIS 分类器

在最近的研究中, 许多跨领域的技术应用取得

了很好的效果. 本文通过利用卷积神经网络中的全连接层拓展经典 TSK 模糊系统的解模糊层, 使单个拓展后的 TSK 模糊系统具备多分类的能力. 其结构如图 6 所示, 其中方形节点代表含系统参数的自适应节点, 圆形节点代表无系统参数的固定节点.

考虑在一个 P 类分类问题中, 训练数据集为 $D = \{(\mathbf{x}_n, \mathbf{t}_n)\}_{n=1}^N$, 其中, N 为训练集大小, $\mathbf{x}_n = (x_1^{(n)}, x_2^{(n)}, \dots, x_M^{(n)})$ 是第 n 个实例的 M 维特征向量, $\mathbf{t}_n = (t_1^{(n)}, t_2^{(n)}, \dots, t_P^{(n)})$ 是其 P 类问题中的 P 维类别标签向量. 需要注意的是, 类别标签向量中只有一个维度的值为 1, 如 $t_i^{(n)} = 1$; 其余维度的值均为 0, 表示特征向量对应于类别 i .

假设规则库有 R 条模糊 If-then 规则, 第 r 条规则的内容为: If $x_1^{(n)}$ is $A_{r,1}$, $x_2^{(n)}$ is $A_{r,2}$, \dots , $x_M^{(n)}$ is $A_{r,M}$, then $f_r = \sum_{m=1}^M (x_m^{(n)} w_{r,m}) + b_{r,0}$. 其中, $A_{r,m}$ 为第 r 条规则中第 m 维输入模糊化后的隶属度, $w_{r,m}$ 为权系数, $b_{r,0}$ 为偏差.

记第 i 层的节点输出为 O^i , 则 MC_ANFIS 每一层的节点方程如下.

第 1 层: 模糊化, 计算每个输入特征的隶属度. 其中 $c_{r,m}$ 为隶属函数的中心, $\sigma_{r,m}$ 为隶属函数的标准差. $c_{r,m}$ 与 $\sigma_{r,m}$ 组成 MC_ANFIS 的前件参数.

$$O_{r,m}^1 = A_{r,m} = \exp\left(-\frac{(x_m - c_{r,m})^2}{2\sigma_{r,m}^2}\right) \quad (9)$$

第 2 层: 计算每条规则的触发强度

$$O_r^2 = \omega_r = \prod_{m=1}^M A_{r,m} \quad (10)$$

第 3 层: 触发强度归一化

$$O_r^3 = \bar{\omega}_r = \frac{\omega_r}{\sum_{r=1}^R \omega_r} \quad (11)$$

第 4 层: 计算每条规则的加权输出

$$O_r^4 = \bar{\omega}_r f_r = \bar{\omega}_r \left(\sum_{m=1}^M (x_m w_{r,m}) + b_{r,0} \right) \quad (12)$$

第 5 层: 解模糊. 用权矩阵 $V \in \mathbf{R}^{R \times P}$ 将所有规则输出映射到每个类别得分. 第 r 条规则对应类别 p 的权重记为 $v_{rp} \in V$, v_{rp} 与 $w_{r,m}$, $b_{r,0}$ 共同组成后件参数. 每个类别的得分计算如下

$$O_p^5 = s_p = \sum_{r=1}^R (O_r^4 v_{rp}) \quad (13)$$

第 6 层: 将类别得分转化为类别概率

$$O_p^6 = y_p = \frac{\exp(O_p^5)}{\sum_{p=1}^P \exp(O_p^5)} \quad (14)$$

第 7 层: 将最大概率对应的类别记为最终的分类结果. 例如, 假设 O_p^6 为第 6 层输出的最大值, 则分类器输出类别为 p .

$$O^7 = O_o = \text{index}(\max(\{O_p^6\}_{p=1}^P)) \quad (15)$$

这样, 通过权矩阵 V 拓展后, MC_ANFIS 具备多分类能力. 即仅需训练好一个 MC_ANFIS 分类器的系统参数, 就可以完成多分类任务, 能够大幅节省计算量, 缩短训练时间.

由于 MC_ANFIS 的每一层节点函数都连续可导, 所以直接由链式法则和误差反向传播更新参数. 在反向传播过程中, 记代价函数为 C (认为 C 中不包含与系统参数直接相关的项), 结构风险函数为 J . 则目标函数 $O = C + J$ 对于 MC_ANFIS 的前件参数和后件参数梯度计算如下:

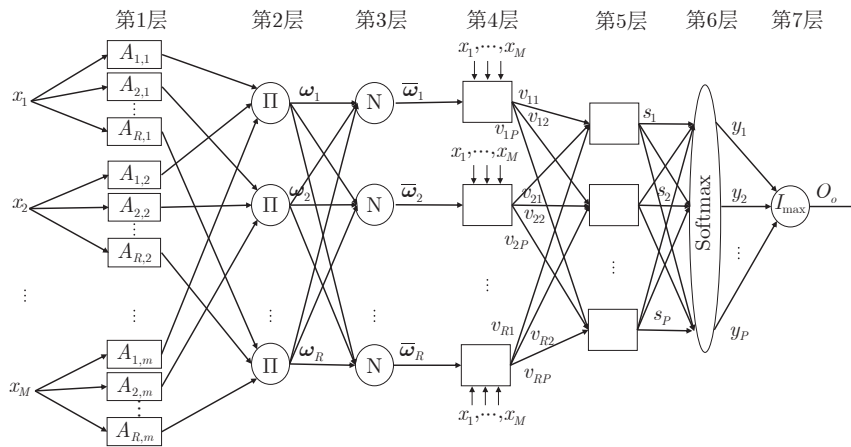


图 6 MC_ANFIS 结构图

Fig. 6 Structure of MC_ANFIS

$$\frac{\partial O}{\partial c_{r,m}} = \sum_{p=1}^P \frac{\partial C}{\partial O_p^6} \left\{ \sum_{i=1}^P \frac{\partial O_p^6}{\partial O_i^5} \left[\sum_{j=1}^R \frac{\partial O_i^5}{\partial O_j^4} \frac{\partial O_j^4}{\partial O_j^3} \frac{\partial O_j^3}{\partial O_r^2} \times \frac{\partial O_r^2}{\partial O_{r,m}^1} \frac{\partial O_{r,m}^1}{\partial c_{r,m}} \right] \right\} + \frac{\partial J}{\partial c_{r,m}} \quad (16)$$

$$\frac{\partial O}{\partial \sigma_{r,m}} = \sum_{p=1}^P \frac{\partial C}{\partial O_p^6} \left\{ \sum_{i=1}^P \frac{\partial O_p^6}{\partial O_i^5} \left[\sum_{j=1}^R \frac{\partial O_i^5}{\partial O_j^4} \frac{\partial O_j^4}{\partial O_j^3} \frac{\partial O_j^3}{\partial O_r^2} \times \frac{\partial O_r^2}{\partial O_{r,m}^1} \frac{\partial O_{r,m}^1}{\partial \sigma_{r,m}} \right] \right\} + \frac{\partial J}{\partial \sigma_{r,m}} \quad (17)$$

$$\frac{\partial O}{\partial w_{r,m}} = \sum_{p=1}^P \frac{\partial C}{\partial O_p^6} \left\{ \sum_{i=1}^P \left[\frac{\partial O_p^6}{\partial O_i^5} \frac{\partial O_i^5}{\partial O_r^4} \frac{\partial O_r^4}{\partial w_{r,m}} \right] \right\} + \frac{\partial J}{\partial w_{r,m}} \quad (18)$$

$$\frac{\partial O}{\partial b_{r,0}} = \sum_{p=1}^P \frac{\partial C}{\partial O_p^6} \left\{ \sum_{i=1}^P \left[\frac{\partial O_p^6}{\partial O_i^5} \frac{\partial O_i^5}{\partial O_r^4} \frac{\partial O_r^4}{\partial b_{r,0}} \right] \right\} + \frac{\partial J}{\partial b_{r,0}} \quad (19)$$

$$\frac{\partial O}{\partial v_{rp}} = \sum_{i=1}^P \frac{\partial C}{\partial O_i^6} \left\{ \sum_{j=1}^P \frac{\partial O_i^6}{\partial O_p^5} \frac{\partial O_p^5}{\partial v_{rp}} \right\} + \frac{\partial J}{\partial v_{rp}} \quad (20)$$

一般用交叉熵作为损失函数 L , 即 $L(\mathbf{t}_i, \mathbf{y}(\mathbf{x}_i)) = \sum_{p=1}^P t_p^{(i)} \ln(y_p(x_i))$. 这样, 式 (16) ~ 式 (20) 化简之后的经验风险与第 6 层输出的变化梯度无关, 可以有效避免训练样本分布的变化对分类器学习过程的影响. 此时, 代价函数 C 计算如下:

$$C = \frac{1}{N} \sum_{n=1}^N \left[- \sum_{p=1}^P t_p^{(n)} \ln(y_p(x_n)) \right] \quad (21)$$

2.2 MC_TS_UR 融合算法

从第 2.1 节可知, MC_ANFIS 提供了一种通用的多分类器架构, 通过误差反向传播而具有自学习的能力. 因此, MC_ANFIS 具体的学习效果受损失函数的选择、梯度更新的策略影响较大, 需要合适的算法优化分类器的性能. MC_ANFIS 是拓展的 ANFIS, 继承了 ANFIS 所具备的神经网络的学习、建模能力和 TSK 模糊系统的知识表达特性, 所以神经网络和模糊系统的优化算法同样适用于 MC_ANFIS.

在分类器的训练过程中, 为了综合提升训练质量和训练效率, 通常用简单随机抽样的方式从训练集中抽取数量为 B_s 的小批量样本代替整个训练集

进行训练. 注意到小批量样本的质量直接关系到算法的学习质量, 而简单随机抽样没有考虑到训练集样本分布的影响, 所以训练得到的分类器泛化性能不能得到保证.

典型抽样 (Typical sampling, TS) 是最近提出的一种神经网络优化算法^[21]. 通过设定阈值 γ_T , 将训练集按概率密度划分为概率密度高的典型集 H 和概率密度低的非典型集 L 两种, 然后分别从 H 和 L 中随机抽取数量为 B_s 的样本组成每次训练用的小批量样本 B_{ts} . 通过调节阈值 γ_T 和小批量样本 B_{ts} 中抽取的 H 和 L 样本比例 α_T , 可以让小批量样本最大限度地符合总体的分布特点. 注意到每次迭代中实际参与训练的为 B_{ts} 中的 B_s 个实例. 在使用 TS 算法后, 式 (21) 应修改为:

$$C = \frac{1}{N_{B_s}} \sum_{n=1}^{N_{B_s}} \left[- \sum_{p=1}^P t_p^{(n)} \ln(y_p(x_n)) \right] \quad (22)$$

在 TSK 模糊系统学习过程中, 容易出现各规则触发强度不均匀的情况, 在极端情况下, 一些规则的触发强度甚至接近于零. 这不仅会浪费计算机的计算量, 甚至会损害系统的性能.

标准正则化 (Uniform regularization, UR) 是最近提出的一种 TSK 模糊系统优化算法^[22]. 通过增加结构风险函数 J_u 的方式, 让各规则的触发强度尽可能相等, 从而提高系统的性能. 记 UR 的系数为 λ_u , 则 J_u 计算如下:

$$J_u = \frac{\lambda_u}{2} \sum_{r=1}^R \left(\frac{1}{N_{B_s}} \sum_{n=1}^{N_{B_s}} \bar{\omega}_r(x_n) - \frac{1}{R} \right)^2 \quad (23)$$

注意到 J_u 与 MC_ANFIS 后件参数无关, 所以代入到目标函数 O 中之后, 后件参数的梯度计算不变.

为增加系统泛化性能, 还需要加入较小的 L_2 正则化结构风险项 J_2 , 降低后件参数的结构风险. 记 L_2 正则化系数为 λ_2 , J_2 由下式计算得到:

$$J_2 = \frac{\lambda_2}{2} \sum_{r=1}^R \sum_{m=1}^M w_{r,m}^2 \quad (24)$$

引入上述优化后, 神经模糊系统的学习过程显著变化, 相应的反向传播的梯度同样改变, 重新推导如下:

$$\frac{\partial O}{\partial c_{r,m}} = - \frac{1}{N_{B_s}} \sum_{n=1}^{N_{B_s}} \left\{ \sum_{p=1}^P t_p^{(n)} \left(- \sum_{i=1, i \neq p}^P y_i(x_n) \times \left[- \sum_{j=1, j \neq r}^R v_{ji} f_j(x_n) \frac{\bar{\omega}_j^2(x_n)}{\omega_j(x_n)} \omega_r(x_n) + v_{ri} \times \right. \right. \right.$$

$$\begin{aligned}
& f_r(x_n)\bar{\omega}_r(x_n)(1 - \bar{\omega}_r(x_n)) \Big] + (1 - y_p(x_n)) \times \\
& \left[- \sum_{j=1, j \neq r}^R v_{jp} f_j(x_n) \frac{\bar{\omega}_j^2(x_n)}{\omega_j(x_n)} \omega_r(x_n) + v_{rp} \times \right. \\
& \left. f_r(x_n)\bar{\omega}_r(x_n)(1 - \bar{\omega}_r(x_n)) \right] + \lambda_u \times \\
& \sum_{k=1, k \neq r}^R \left(\bar{\omega}_k(x_n) - \frac{1}{R} \right) \frac{\bar{\omega}_k^2(x_n)}{\omega_k(x_n)} \omega_r(x_n) - \lambda_u \times \\
& \left(\bar{\omega}_r(x_n) - \frac{1}{R} \right) \bar{\omega}_r(x_n)(1 - \bar{\omega}_r(x_n)) \Big\} \frac{x_m^{(n)} - c_{r,m}}{(\sigma_{r,m})^2} \quad (25)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial O}{\partial \sigma_{r,m}} &= -\frac{1}{N_{B_s}} \sum_{n=1}^{N_{B_s}} \left\{ \sum_{p=1}^P t_p^{(n)} \left(- \sum_{i=1, i \neq p}^P y_i(x_n) \times \right. \right. \\
& \left. \left[- \sum_{j=1, j \neq r}^R v_{ji} f_j(x_n) \frac{\bar{\omega}_j^2(x_n)}{\omega_j(x_n)} \omega_r(x_n) + v_{ri} \times \right. \right. \\
& \left. \left. f_r(x_n)\bar{\omega}_r(x_n)(1 - \bar{\omega}_r(x_n)) \right] + (1 - y_p(x_n)) \times \right. \\
& \left. \left[- \sum_{j=1, j \neq r}^R v_{jp} f_j(x_n) \frac{\bar{\omega}_j^2(x_n)}{\omega_j(x_n)} \omega_r(x_n) + v_{rp} \times \right. \right. \\
& \left. \left. f_r(x_n)\bar{\omega}_r(x_n)(1 - \bar{\omega}_r(x_n)) \right] \right\} + \lambda_u \times \\
& \sum_{k=1, k \neq r}^R \left(\bar{\omega}_k(x_n) - \frac{1}{R} \right) \frac{\bar{\omega}_k^2(x_n)}{\omega_k(x_n)} \omega_r(x_n) - \lambda_u \times \\
& \left(\bar{\omega}_r(x_n) - \frac{1}{R} \right) \bar{\omega}_r(x_n)(1 - \bar{\omega}_r(x_n)) \Big\} \frac{(x_m^{(n)} - c_{r,m})^2}{(\sigma_{r,m})^3} \quad (26)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial O}{\partial w_{r,m}} &= -\frac{1}{N_{B_s}} \sum_{n=1}^{N_{B_s}} \left\{ \sum_{p=1}^P t_p^{(n)} \left[\sum_{i=1, i \neq p}^P y_i(x_n) \times \right. \right. \\
& \left. \left. v_{ri} \bar{\omega}_r(x_n) \right] + [(1 - y_p(x_n)) v_{rp} \bar{\omega}_r(x_n)] x_m^{(n)} \right\} + \\
& \lambda_2 w_{r,m} \quad (27)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial O}{\partial b_{r,0}} &= -\frac{1}{N_{B_s}} \sum_{n=1}^{N_{B_s}} \left\{ \sum_{p=1}^P t_p^{(n)} \left[\sum_{i=1, i \neq p}^P y_i(x_n) \times \right. \right. \\
& \left. \left. v_{ri} \bar{\omega}_r(x_n) \right] + [(1 - y_p(x_n)) v_{rp} \bar{\omega}_r(x_n)] \right\} \quad (28)
\end{aligned}$$

$$\begin{aligned}
\frac{\partial O}{\partial v_{rp}} &= -\frac{1}{N_{B_s}} \sum_{n=1}^{N_{B_s}} \left\{ \sum_{p=1}^P t_p^{(n)} \left[\sum_{i=1, i \neq p}^P y_i(x_n) + \right. \right. \\
& \left. \left. (1 - y_p(x_n)) \bar{\omega}_r(x_n) f_r(x_n) \right] \right\} \quad (29)
\end{aligned}$$

本文提出的 MC_TS_UR 优化算法是在 MC_ANFIS 的架构上, 融合最近提出的神经网络优化算法 TS、模糊系统优化算法 UR、 L_2 正则化以及 ad-aBound 等经典机器学习优化算法的融合自适应算法。MC_TS_UR 融合算法流程见算法 1。

算法 1. MC_TS_UR 融合算法

输入. 超参数 $\gamma_T, \alpha_T, \lambda_u, \alpha, B_S, N_{it}, \lambda_r, \beta_2$ 。

输出. 系统参数 $c_{r,m}, \sigma_{r,m}, b_{r,m}, v_{rp}$ 。

- 1) 初始化: $c_{r,m} = 0, \sigma_{r,m} = 0, b_{r,m} = 0, v_{rp} = 0$;
- 2) 计算每个样本的二维概率密度, 然后用阈值 γ_T 划分典型集 H 和非典型集 L ;
- 3) **do**
- 4) 从 H 和 L 中分别挑选 $B_S \cdot \alpha_T$ 和 $B_S \cdot (1 - \alpha_T)$ 个样本组成大小为 B_S 的小批量样本 B_{ts} ;
- 5) **for** $i = 1:B_S$
- 6) 从小批量样本 B_{ts} 中抽取第 i 个样本;
- 7) 根据式 (9) ~ 式 (15) 计算该样本的前向传播结果;
- 8) 根据式 (24) ~ 式 (28) 计算该样本的损失对于每个参数的梯度;
- 9) **end**
- 10) 用 AdaBound 自适应学习率和计算的平均梯度更新系统参数 $c_{r,m}, \sigma_{r,m}, b_{r,m}, v_{rp}$;
- 11) 迭代次数加 1;
- 12) **until** 当前迭代次数大于最大迭代次数 N_{it} ;
- 13) **return** $c_{r,m}, \sigma_{r,m}, b_{r,m}, v_{rp}$ 。

从 TS、UR 两种算法本身的特点来看, 所提融合算法具备以下特性: 1) 能精确反映总体特性, 即有优秀的泛化能力; 2) 优化系统结构, 让所有规则都能发挥其应有的作用, 即能表现出很好的性能。

3 手势识别实验

本节通过手势识别离线实验验证所提手势识别方法的性能。

3.1 实验设置

本文主要识别 6 种手腕手势: 屈腕、伸腕、伸掌、握拳、尺侧倾和桡侧倾, 如图 7 所示。控制 6 种手腕手势对应的肌肉信息在表 2 中给出。

本文研究中手势识别的方案如下: 先用可穿戴式设备采集对应的 6 块肌肉气压肌动图以获取原始手势数据, 然后通过数据降维、格式转换等方法预处理数据。数据采集方法详见第 1.2 节, 预处理的方法详见第 1.3 节。经 8 位受试者手势数据预处理, 得到 PCA 降维后的维度为 $M = 7$ 。将处理后的数据打上标签后划分训练集 (80%) 和测试集 (20%), 用 5 折交叉验证的方式训练 IMNFIS 以及测试 IMNFIS



图 7 本文研究的 6 种手势

Fig. 7 Six gestures studied in this paper

表 2 6 种手腕手势对应的肌肉信息

Table 2 Muscles information of the corresponding six gestures

手势	肌肉	作用
屈腕	尺侧腕屈肌	手腕屈曲和尺侧偏移
握拳	指浅屈肌	手指弯曲
尺侧倾	桡侧腕屈肌	手腕弯曲和径向偏移
伸腕	尺侧腕伸肌	手腕伸展和尺侧偏移
伸掌	指伸肌	手指伸展
桡侧倾	桡侧腕伸肌	手腕伸展和径向偏移

的训练效果. 本文实验是在一台配置为 16G RAM、3.2 GHz core i7 8700K 的计算机上进行的.

3.2 模型和算法

本次实验比较了几种经典分类算法, 如支持向量机 (Support vector machine, SVM)、梯度增强决策树 (Gradient boosting decision tree, GBDT)、线性判别分析 (Linear discriminant analysis, LDA)、一种基于 ANFIS 的经典神经模糊系统优化方法 (TSK_GD_LSE), 以及几种基于 MC_ANFIS 和小批量梯度下降的 TSK 模糊系统优化算法 (MC、MC_TS、MC_UR 和 MC_TS_UR). 模型和算法的设置如下.

1) SVM: 在 Python 中调用 Scikit-learn 库函数实现. 使用 5 折交叉验证从 {0.05, 0.1, 1, 10, 20} 中选择惩罚系数, 使用 'rbf' 核, 'auto' 核系数, 'ovr' 决策函数以及默认的其他参数初始化分类器.

2) GBDT: 在 Python 中调用 Scikit-learn 库函数实现. 使用 5 折交叉验证从 {3, 4, 5, 6} 中选择最大深度, 其余参数设置为默认.

3) LDA: 在 Python 中调用 Scikit-learn 库函数实现. 使用 5 折交叉验证从 {0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9} 中选择惩罚项 'shrinkage', 使用 'eigen' 求解器, 其余参数设置为默认.

4) TSK_GD_LSE: 用一般 ANFIS 的分类器模型. 通过 'ovr' 的分类策略, 将多分类问题转化为多个 ANFIS 的二分类问题. 最后比较所有二分类器的结果, 决定最终的分类结果, 按照以下方法训练每个二分类器. 系统参数均初始化为 0. 在前向传播中使用迭代最小二乘法确定先行参数, 在反向传播中使用梯度下降结合 L_2 正则化确定后件参数. 所有超参数均设置为默认或者典型值 ($\lambda_2 = 0.05$).

5) MC: 用 MC_ANFIS 的分类器模型. 系统参数初始化为 0. 先用简单随机抽样的方式从训练集中随机选取 mini-batch, 然后用 L_2 正则化结合 AdaBound 更新参数. 所有超参数均设置为默认或者典型值 ($\lambda_2 = 0.05$, $\beta_2 = 0.999$).

6) MC_TS: 用 MC_ANFIS 的分类器模型. 系统参数初始化为 0. 先用典型抽样的方式从训练集中随机选取 mini-batch, 然后用 L_2 正则化结合 AdaBound 更新参数. 所有超参数均设置为默认或者典型值 ($\gamma_T = 0.8$, $\alpha_T = 0.8$, $\lambda_2 = 0.05$, $\beta_2 = 0.999$).

7) MC_UR: 用 MC_ANFIS 的分类器模型. 系统参数初始化为 0. 先用简单随机抽样的方式从训练集中随机选取 mini-batch, 然后用 UR + L_2 正则化结合 AdaBound 更新参数. 使用 5 折交叉验证从 {0.1, 1, 10, 100} 中选择 UR 系数 λ_u , 其余超参数均设置为默认或者典型值 ($\lambda_2 = 0.05$, $\beta_2 = 0.999$).

8) MC_TS_UR: 用 MC_ANFIS 的分类器模型. 系统参数初始化为 0. 先用典型抽样的方式从训练集中随机选取 mini-batch, 然后用 UR + L_2 正则化结合 AdaBound 更新参数. 使用 5 折交叉验证从 {0.1, 1, 10, 100} 中选择 UR 系数 λ_u , 其余超参数均设置为默认或者典型值 ($\gamma_T = 0.8$, $\alpha_T = 0.8$, $\lambda_2 = 0.05$, $\beta_2 = 0.999$).

3.3 评价指标

本文设计了以下指标评价识别性能: 1) 混淆矩阵 (Confusion matrix, CM); 2) 原始错误率 (Raw error rate, RER); 3) 平衡错误率 (Balanced error rate, BER); 4) kappa 系数 κ ; 5) 训练时间 T_i . 评价指标 1) ~ 4) 根据训练的小批量样本以及测试集的 CM 计算得到, 是一般分类任务的常用指标; 评价指标 5) 用于评估算法的训练效率.

这些指标的计算如下:

1) 混淆矩阵 CM. 混淆矩阵中每一行代表真实标签为该行数的分类情况. 例如, 混淆矩阵中第 i 行

j 列的数值为该分类器将真实标签为第 i 类的数据判定为第 j 类的样本占真实标签为第 i 类的总样本数的百分比. CM 对角线原素越大越好.

2) 原始错误率 RER

$$\text{RER} = \left(\frac{\sum_{p=1}^P F^{(p)}}{\sum_{p=1}^P T^{(p)} + \sum_{p=1}^P F^{(p)}} \right) \times 100\% \quad (30)$$

其中,

p 为类别索引, 即第 p 类;

P 为分类的类别数, 本文中对 6 种手腕手势分类, 即 $P = 6$;

$T^{(p)}$ 为标签为第 p 类的样本被正确分类的数目;

$F^{(p)}$ 为标签为第 p 类的样本被错误分类的数目.

3) 平衡错误率 BER

$$\text{BER} = \left(\sum_{p=1}^P \frac{F^{(p)}}{T^{(p)} + F^{(p)}} \right) P^{-1} \times 100\% \quad (31)$$

4) κ 系数. 一种用于评价所设计分类器或算法效率的系数, 用于涉及到识别两个以上类的多类问题. 该系数的数值越高, 表示结果越好.

$$\kappa = \left(\frac{M \sum_{p=1}^P m_{p,p} - \sum_{p=1}^P (G_p C_p)}{M^2 - \sum_{p=1}^P (G_p C_p)} \right) \quad (32)$$

其中,

M 为待分类样本总数, 即测试集大小;

$m_{p,p}$ 为标签为第 p 类且同时被分类器判定为第 p 类的样本数;

G_p 为标签为第 p 类的样本总数;

C_p 为被分类器判定为第 p 类的样本总数.

5) 训练时间 T_t . 训练时间包括: a) 数据降维、标签数据格式转换和数据集划分等将采集的原始手势、标签数据转化为分类器可直接操作数据的数据预处理时间; b) 数据预处理后, 从分类器初始化到分类器学习过程完成的纯粹用于分类器自学习的总时间. T_t 越小, 分类器的实用性和学习效率越高, 更适合用于开发手势识别的在线产品.

以上指标用于评估本研究中的机器学习方法在手势识别中的性能. 其中, CM 可以验证单个类别的识别性能, T_t 可以验证算法的可拓展性, 其余指标可以验证分类器整体的识别性能.

3.4 离线实验结果

本节对于健康人和残疾人两种对象分别给出第 3.2 节列出的 8 种机器学习算法的离线手势分类

结果, 并对其进行分析与讨论.

考虑到收集到的数据集较大 (每名受试者约 50 万组数据) 且 MATLAB 能够使用的内存有限, 直接读取所有数据的话, 会有内存溢出的风险. 因此, 按照每 10 万组数据为一个数据集, 将实验数据 5 等分进行手势识别的离线实验. 分别在每个子数据集上用 5 折交叉验证的方式训练, 然后将 5 个子数据集的平均分类错误率作为每个受试者的最终平均分类错误率.

融合算法在每名受试者数据集上的混淆矩阵如图 8 所示. 由图 8 可知, 利用肌动图识别手腕手势时, 伸腕手势和伸掌的识别效果较差且容易互相混淆. 这可能是因为受试者们在采集手势数据的过程中动作不够标准引起的, 在采集伸腕手势数据时不自觉地也有轻微的伸掌动作. 而握拳、手尺侧倾和手桡侧倾则不容易与其他手势混淆, 所以识别效果更好, 在受试者的数据集上几乎都达到 98.5% 以上.

最后在 7 名健康人受试者的数据集上, 用第 3.2 节提到的 8 种算法计算第 3.4 节中给出的指标. 表 3 和表 4 分别给出了健康人与残疾人实验的平均结果, 该结果由健康人和残疾人两种对象的所有受试者实验结果取平均得到. 可以看到在健康人的数据集上, 相比于 SVM、GBDT 等传统机器学习算法, 本文所提的融合算法在测试集误差上有明显的减少而 κ 系数明显提高. 基于 ANFIS 的分类性能高于 SVM 等传统机器学习算法, 这与文献 [23-24] 中所述的结论一致. 4 种基于 MC_ANFIS 的算法的结果均优于传统 ANFIS 优化方法且训练时间 T_t 更短, 说明 MC_ANFIS 的结构在处理多分类问题时有更大的优势. 训练时间更短的原因在第 2.1 节已经分析过, 是因为需要训练的分类器数量少, 节省了大量数据预处理时间和学习时间. 分类效果更好可能是在 ‘ovr’ 的分类策略中, 每个类的分类器之间的训练是独立的, 而 MC_ANFIS 则是在第 5 层中综合了全部的类别输出信息. 融合算法相比于纯 MC 方法, 测试误差更小并小于训练误差, 平均训练时间更是缩短了一半以上, 说明融合算法除了分类性能好、泛化能力强以外, 计算效率也得到了很大的提升.

而在残疾人的数据集上, 本文提出的 MC_TS_UR 融合算法表现出的性能同样优秀. 在错误率极低的情况下, 同样大幅缩减了训练时间. 与表 3 相比, 表 4 中 8 种算法在 CER、BER 等指标上有不同程度的上升而 κ 系数略有减少. 这可能是因为相比于健康人受试者, 残疾人受试者的腕部肌肉功能已经发生了遗忘或退化, 所以残疾人受试者的手势意图不够明确、准确. 尽管如此, MC_TS_UR 融合

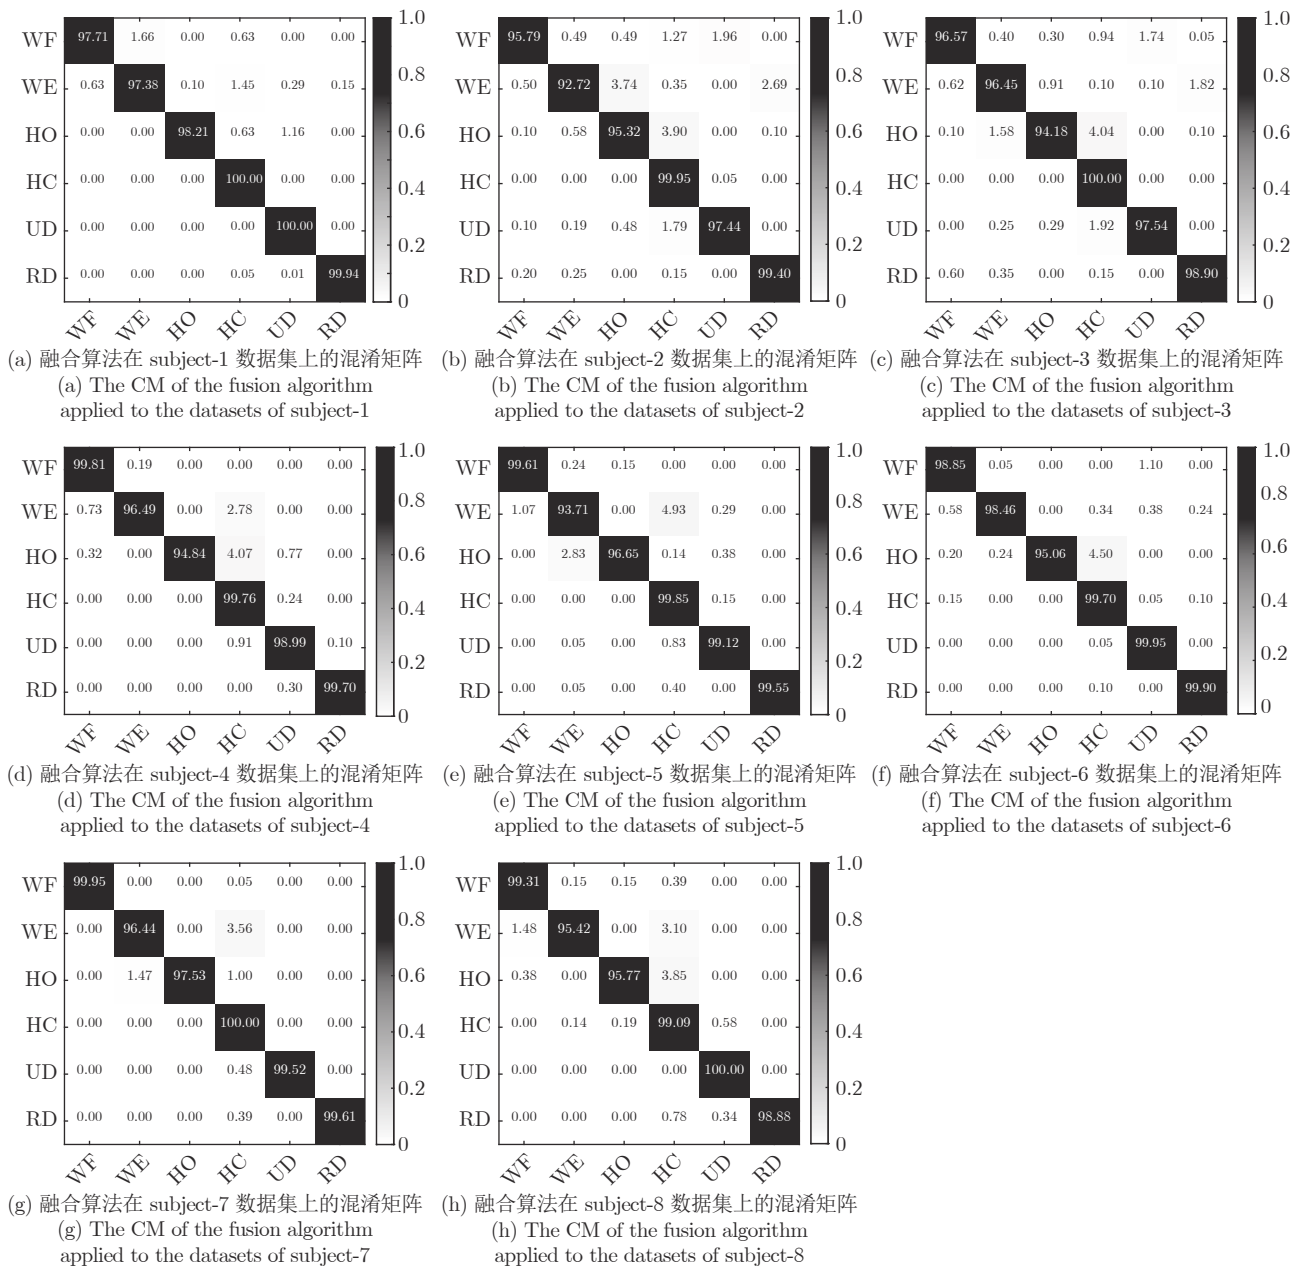


图 8 MC_TS_UR 融合算法在每名受试者数据集上的混淆矩阵

Fig.8 The CM of the MC_TS_UR fusion algorithm applied to the datasets of every subject

表 3 8 种算法在健康人数据集上的离线实验结果

Table 3 The offline experiment results of eight algorithms on datasets of the normal

指标	SVM	GBDT	LDA	TSK_GD_LSE	MC	MC_TS	MC_UR	MC_TS_UR
RER	6.07%	7.82%	5.15%	5.26%	3.16%	2.52%	2.30%	1.82%
BER	6.18%	8.74%	5.21%	5.35%	2.83%	2.41%	2.33%	1.77%
κ	0.9258	0.9018	0.9375	0.9358	0.9660	0.9711	0.9720	0.9787
T_t	224.6	4.4	0.6	1121.9	796.1	886.5	734.7	310.2

算法依然达到了 97.25% 的手势识别准确率, 比健康受试者的手势识别准确率仅差 0.93%。

3.5 分析与讨论

图 9 给出了 4 种基于 MC_ANFIS 框架的分类

表 4 8 种算法在残疾人数据集上的离线实验结果

Table 4 The offline experiment results of eight algorithms on datasets of the disabled

指标	SVM	GBDT	LDA	TSK_GD_LSE	MC	MC_TS	MC_UR	MC_TS_UR
RER	5.94%	8.13%	4.46%	5.77%	4.64%	3.83%	3.77%	2.75%
BER	6.10%	8.27%	4.48%	6.11%	4.72%	3.98%	3.65%	2.73%
κ	0.9268	0.9008	0.9462	0.9267	0.9434	0.9522	0.9562	0.9672
T_t	173.0	5.3	0.7	1006.5	766.8	942.9	768.6	313.1

算法的误差随训练时间的变化曲线. 从曲线中容易看出, 用 UR 优化后, 训练时间变化不大, 收敛特性有所提升; TS 优化会略微增加一部分训练时间, 泛化性能得到了增强; 而融合算法在泛化性能和系统收敛特性都提高的同时, 训练时间也得到了大幅缩减. 这可能是因为 TS 和 UR 两种优化方法在融合过程中出现了更深层次的结合, 从而加快了收敛速度, 让训练效率和质量都大幅提升. 本文提出的手势识别方法优于传统机器学习算法, 而相比于一般 MC_ANFIS 分类方法, 能节省大量的训练时间, 更适合用于开发在线的残疾人手势识别产品.

本文与近期手势识别研究工作的比较如表 5 所示. 可以看到, 与同类研究工作相比, 在研究对象为健康人时, 在手势类别数相当的情况下, 本文所提的手势识别方法取得的分类精度最高; 而在研究对象为残疾人时, 本文所提方法在所用的传感器通道数差别不大的情况下, 同样得到了最高的手势识别精度. 综合来看, 本文所提的手势识别方法在识别的手势类别数相当的情况下, 在健康人和残疾人两种类型的受试者上均表现优秀.

4 结束语

为克服残疾人的肢体缺陷, 设计能被残疾人普遍接受的手势识别产品, 本文提出了基于 pMMG 和 IMNFIS 的手势识别方法. 该方法融合了多分类

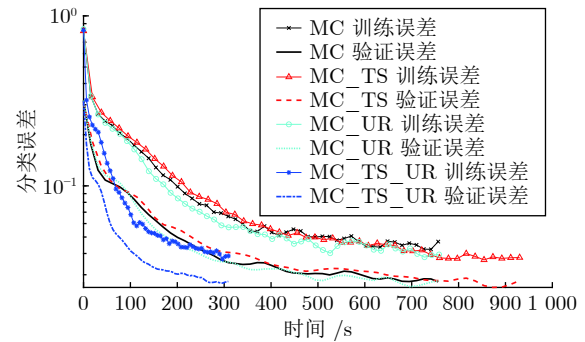


图 9 4 种基于 MC_ANFIS 的算法在训练过程中的分类误差随时间变化曲线

Fig. 9 The classification error changes curve of four MC_ANFIS based algorithms with time during the training process

的神经模糊系统结构、神经网络与模糊系统优化方法, 在分类效果优秀的同时极大地缩短了训练所需的时间. 通过健康人实验和残疾人实验, 分别验证了本文所提的手势识别方法在健康人和残疾人数据集上的有效性和可拓展性. 相比于许多近些年发表文献中的方法, 本文提出的 MC_TS_UR 融合算法、6 个 pMMG 传感器和 1 个 IMU 传感器的手势识别方法对于 6 种手腕手势的识别能力更高.

本文实验仅考虑了离线情形, 而从离线实验到转化为残疾人能够直接使用的产品还有很大的差

表 5 与近期同类研究文献的比较

Table 5 Comparison with similar research work literature

文献	传感器	实验对象	是否为公共数据集	分类算法	手势类别数	识别准确率
[25]	6 通道 pMMG	6 名健康人	否	Fuzzy logic	6	95.30%
[26]	8 通道 FMG	10 名健康人	否	SVM	6	93.00%
[27]	2 通道 sEMG	7 名健康人	否	SVM	4	95.00%
[28]	4 通道 sEMG + 1 通道 IMU	10 名健康人	否	LDA	8	92.60%
[29]	8 通道 sEMG	21 名健康人	否	LDA	6	94.70%
[30]	8 通道 sEMG	8 名健康人	否	Hidden Markov model	6	94.20%
Proposed	6 通道 pMMG + 1 通道 IMU	7 名健康人	否	MC_TS_UR	6	98.18%
[31]	8 通道 sEMG	4 名残疾人	否	LDA	7	92.00%
[32]	7 通道 sEMG	3 名残疾人	否	SVM	5	94.02%
Proposed	6 通道 pMMG + 1 通道 IMU	1 名残疾人	否	MC_TS_UR	6	97.25%

距,且本文实验中仅研究了8名受试者的6种手腕手势,实验对象和手势类别都十分有限。考虑到使用在线的学习方法可以适应不同用户的需求,后续的研究工作会集中在:优化代码结构降低训练时间,离线转在线的学习方法的开发,以及识别更多种类手势能力的推广。

References

- Liu H Y, Wang L H. Gesture recognition for human-robot collaboration: A review. *International Journal of Industrial Ergonomics*, 2018, **68**(1): 355–367
- Ding J, Lin R Z, Lin Z Y. Service robot system with integration of wearable Myo armband for specialized hand gesture human-computer interfaces for people with disabilities with mobility problems. *Computers Electrical Engineering*, 2018, **69**(1): 815–827
- Ding Qi-Chuan, Zhao Xin-Gang, Li Zi-You, Han Jian-Da. An EMG-motion recognition method with self-update hybrid classification model. *Acta Automatica Sinica*, 2019, **45**(8): 1464–1474 (丁其川, 赵新刚, 李自由, 韩建达. 基于自更新混合分类模型的肌电运动识别方法. *自动化学报*, 2019, **45**(8): 1464–1474)
- Zhang X, Chen X, Li Y, Lantz V, Wang K, Yang J. A framework for hand gesture recognition based on accelerometer and EMG sensors. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 2011, **41**(6): 1064–1076
- Duan T, Huang J, Xie Z, Wang L, Xiong C H. Continuous control of wrist-hand prosthesis by extracting independent sEMG signals from cross-talk muscle groups. In: Proceedings of the 2019 Chinese Control Conference. Guangzhou, China: IEEE, 2019. 4537–4542
- Li Zi-You, Wang Feng-Yan, Zhao Xin-Gang, Ding Qi-Chuan, Zhang Dao-Hui, Han Jian-Da. The method for gestures recognition based on Myo rotation shifts estimation and adaptive correction. *Acta Automatica Sinica*, 2020, **46**(9): 1896–1907 (李自由, 王丰焱, 赵新刚, 丁其川, 张道辉, 韩建达. 基于 Myo 旋转偏移估计与自适应校正的手势识别方法. *自动化学报*, 2020, **46**(9): 1896–1907)
- Orizio C, Liberati D, Locatelli C, Grandis D D, Veicsteinas A. Surface mechanomyogram reflects muscle fibres twitches summation. *Journal of Biomechanics*, 1996, **29**(4): 475–481
- Akataka K, Mita K, Watakabe M, Itoh K. Mechanomyogram and force relationship during voluntary isometric ramp contractions of the biceps brachii muscle. *European Journal of Applied Physiology*, 2001, **84**(1-2): 19–25
- McIntosh J, Marzo A, Fraser M, Phillips C. Echoflex: Hand gesture recognition using ultrasound imaging. In: Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems. Denver, USA: ACM, 2017. 1923–1934
- Liu M K, Lin Y T, Qiu Z W, Kuo C K, Wu C K. Hand gesture recognition by a MMG-based wearable device. *IEEE Sensors Journal*, 2020, **20**(24): 14703–14712
- Feng W, Xia C, Zhang Y, Yu J, Jiang W. Research on Chinese sign language recognition methods based on mechanomyogram signals analysis. In: Proceedings of the 4th International Conference on Signal and Image Processing. Wuxi, China: IEEE, 2019. 46–50
- Stokes M J, Dalton P A. Acoustic myographic activity increases linearly up to maximal voluntary isometric force in the human quadriceps muscle. *Journal of the Neurological Sciences*, 1991, **101**(2): 163–167
- Ahsan M R, Ibrahimy M I, Khalifa O O. Electromyography (EMG) signal based hand gesture recognition using artificial neural network (ANN). In: Proceedings of the 4th International Conference on Mechatronics. Kuala Lumpur, Malaysia: IEEE, 2011. 1–6
- Zhang Z, Yang K, Qian J, Zhang L. Real-time surface emg pattern recognition for hand gestures based on an artificial neural network. *Sensors*, 2019, **19**(14): 3170–3184
- Yao B, Hagrass H, Alhaddad M J, Alghazzawi D. A fuzzy logic-based system for the automation of human behavior recognition using machine vision in intelligent environments. *Soft Computing*, 2015, **19**(2): 499–506
- Hachaj T, Ogiela M R. Rule-based approach to recognizing human body poses and gestures in real time. *Multimedia Systems*, 2014, **20**(1): 81–99
- Mufarroha F A, Utamingrum F. Hand gesture recognition using adaptive network based fuzzy inference system and k-nearest neighbor. *International Journal of Technology*, 2017, **8**(3): 559–567
- Khezri M, Jahed M. A neuro-fuzzy inference system for sEMG-based identification of hand motion commands. *IEEE Transactions on Industrial Electronics*, 2010, **58**(5): 1952–1960
- Hill A V. The heat of shortening and the dynamic constants of muscle. *Proceedings of the Royal Society of London*, 1938, **126**(843): 136–195
- Belyea A, Englehart K, Scheme E. FMG vs EMG: A comparison of usability for real-time pattern recognition based control. *IEEE Transactions on Biomedical Engineering*, 2019, **66**(11): 3098–3104
- Peng X Y, Li L, Wang F Y. Accelerating minibatch stochastic gradient descent using typicality sampling. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, **31**(11): 4649–4659
- Cui Y Q, Wu D R, Huang J. Optimize TSK fuzzy systems for classification problems: Mini-batch gradient descent with uniform regularization and batch normalization. *IEEE Transactions on Fuzzy Systems*, 2020, **28**(12): 3065–3075
- You H, Ma Z, Tang Y, Wang Y, Yan J, Ni M, et al. Comparison of ANN (MLP), ANFIS, SVM, and RF models for the online classification of heating value of burning municipal solid waste in circulating fluidized bed incinerators. *Waste Management*, 2017, **68**(10): 186–197
- Shariati S, Haghighi M M. Comparison of anfis neural network with several other ANNs and support vector the machine for diagnosing hepatitis and thyroid diseases. In: Proceedings of the 2010 International Conference on Computer Information Systems and Industrial Management Applications. Krakow, Poland: IEEE, 2010. 596–599
- Jung P G, Lim G, Kim S, Kong K. A wearable gesture recognition device for detecting muscular activities based on air-pressure sensors. *IEEE Transactions on Industrial Informatics*, 2015, **11**(2): 485–494
- Anvaripour M, Saif M. Hand gesture recognition using force myography of the forearm activities and optimized features. In: Proceedings of the 2018 IEEE International Conference on Industrial Technology. Lyon, France: IEEE, 2018. 187–192
- Tavakoli M, Benussi C, Lopes P A, Osorio L B, De Almeida A T. Robust hand gesture recognition with a double channel surface EMG wearable armband and SVM classifier. *Biomedical Signal Processing and Control*, 2018, **46**(1): 121–130
- Jiang S, Lv B, Guo W, Zhang C, Wang H, Sheng X, et al. Feasibility of wrist-worn, real-time hand, and surface gesture recognition via sEMG and IMU sensing. *IEEE Transactions on Industrial Informatics*, 2017, **14**(8): 3376–3385
- Botros F, Phinyomark A, Scheme E. EMG-based gesture recognition: Is it time to change focus from the forearm to the wrist?. *IEEE Transactions on Industrial Informatics*, 2022, **18**(1), 174–184
- Shaabana A, Legere J, Li J, Zheng R, Mohrenschildt M V, Shedden J M. Portable electromyography: A case study on ballistic finger movement recognition. *IEEE Sensors Journal*, 2019, **19**(16): 7043–7055
- Powell M A, Kaliki R R, Thakor N V. User training for pattern

recognition-based myoelectric prostheses: Improving phantom limb movement consistency and distinguishability. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, 22(3): 522–532

- 32 Kartsch V, Benatti S, Mancini M, Magno M, Benini L. Smart wearable wristband for EMG based gesture recognition powered by solar energy harvester. In: Proceedings of the 2018 IEEE International Symposium on Circuits and Systems. Florence, Italy: IEEE, 2018. 1–5




汪 雷 华中科技大学人工智能与自动化学院硕士研究生. 2019 年获得华中科技大学学士学位. 主要研究方向为机器学习, 手势识别.

E-mail: wml0531@hust.edu.cn

(WANG Lei Master student at the School of Artificial Intelligence and

Automation, Huazhong University of Science and Technology. He received his bachelor degree from Huazhong University of Science and Technology in 2019. His research interest covers machine learning and gesture recognition.)



黄 剑 华中科技大学人工智能与自动化学院教授. 2005 年获得华中科技大学博士学位. 主要研究方向为康复机器人, 机器人装配, 网络控制系统和生物信息学. 本文通信作者.

E-mail: huang_jan@mail.hust.edu.cn

(HUANG Jian Professor at the School of Artificial Intelligence and Automation, Huazhong University of Science and Technology. He received his Ph.D. degree from Huazhong University of Science and Technology in 2005. His research interest covers rehabilitation robot, robotic assembly, networked control systems, and bioinformatics. Corresponding author of this paper.)



段 涛 2020 年获得华中科技大学硕士学位. 主要研究方向为智能机器人, 模式识别.

E-mail: tao_duan@hust.edu.cn

(DUAN Tao He received his master degree from Huazhong University of Science and Technology

in 2020. His research interest covers intelligent robot and pattern recognition.)



伍冬睿 华中科技大学人工智能与自动化学院教授. 主要研究方向为机器学习, 脑机接口, 计算智能和情感计算. E-mail: drwu@hust.edu.cn

(WU Dong-Rui Professor at the School of Artificial Intelligence and Automation, Huazhong University

of Science and Technology. His research interest covers machine learning, brain-computer interfaces, computational intelligence, and affective computing.)



熊蔡华 华中科技大学机械科学与工程学院数字制造装备与技术国家重点实验室教授. 1998 年获得华中理工大学 (现华中科技大学) 机械电子工程专业博士学位. 主要研究方向为机器人学, 生机电一体化和康复工程装备.

E-mail: chxiong@hust.edu.cn

(XIONG Cai-Hua Professor at the State Key Laboratory of Manufacturing Equipment and Technology, School of Mechanical Science and Engineering, Huazhong University of Science and Technology. He received his Ph.D. degree in mechatronics from Huazhong University of Science and Technology in 1998. His research interest covers robotics, biomechanics, and rehabilitation engineering equipment.)



崔雨琦 华中科技大学人工智能与自动化学院博士研究生. 2017 年获得华中科技大学电子信息工程学士学位. 主要研究方向为模糊系统, 脑机接口和可穿戴设备.

E-mail: yqcui@hust.edu.cn

(CUI Yu-Qi Ph.D. candidate at the School of Artificial Intelligence and Automation, Huazhong University of Science and Technology. He received his bachelor degree in electronic information engineering from Huazhong University of Science and Technology in 2017. His research interest covers fuzzy systems, brain-computer interfaces, and wearable devices.)