

基于结构优化的 DDAG-SVM 上肢康复训练动作识别方法

左国玉^{1,2} 徐兆坤^{1,2} 卢佳豪^{1,2} 龚道雄^{1,2}

摘要 针对上肢康复训练系统中训练评估方法核心的动作识别问题, 提出一种面向 Brunnstrom 4~5 期患者上肢康复训练动作的 SODDAG-SVM (Structure-optimized decision directed acyclic graph-support vector machine) 多分类识别方法. 首先将多分类问题分解成一组二分类问题, 并使用支持向量机构建各二分类器, 分别采用遗传算法和特征子集区分度准则对各二分类器的核函数参数及特征子集进行优化. 然后使用类对的 SVM 二分类器泛化误差来衡量每个类对的易被分离程度, 并由其建立类对泛化误差上三角矩阵. 最后由根节点开始, 依次根据各节点的泛化误差矩阵, 通过选择其中最易被分离类对的 SVM 分类器构成该节点的方式, 来构建 SODDAG-SVM 多分类器结构. 当待预测的实例较少时, 直接构建实例经过的 SODDAG-SVM 部分结构并对实例进行预测; 当待预测的实例较多时, 先构建完整的 SODDAG-SVM 结构, 再代入所有实例进行预测. 通过人体传感技术获得 Brunnstrom 4~5 阶段上肢康复训练的常用动作样本集, 进行 SODDAG-SVM 动作识别实验, 准确率达到了 95.49%, 结果均优于常规的决策有向无环图 (Decision directed acyclic graph, DDAG) 和 MaxWins 方法, 实验表明本文方法能有效地提高上肢康复训练动作识别的准确率.

关键词 上肢康复训练, 动作识别, SODDAG-SVM, 多分类器, 二分类器

引用格式 左国玉, 徐兆坤, 卢佳豪, 龚道雄. 基于结构优化的 DDAG-SVM 上肢康复训练动作识别方法. 自动化学报, 2020, 46(3): 549–561

DOI 10.16383/j.aas.c170724

A Structure-optimized DDAG-SVM Action Recognition Method for Upper Limb Rehabilitation Training

ZUO Guo-Yu^{1,2} XU Zhao-Kun^{1,2} LU Jia-Hao^{1,2} GONG Dao-Xiong^{1,2}

Abstract An SODDAG-SVM (structure-optimized decision directed acyclic graph-support vector machine) multi-classification action recognition method of upper limb rehabilitation training for the Brunnstrom 4~5 stage patients is proposed to solve the core problem of action recognition of the rehabilitation training evaluation method. First, the multi-classification problem is decomposed into a set of binary classification problems, support vector machine (SVM) method is used to construct each binary classifier, in which the SVM kernel function parameters and feature subsets of each binary classifiers are optimized by genetic algorithm and the feature subsets discrimination criterion, respectively. Then, the generalization errors of each SVM binary classifier are used to measure the separable degree of this class pair, and the upper triangulation matrix of generalization errors is built. Finally, from the root node, according to the generalization error matrix of each node, an SODDAG-SVM structure is constructed by choosing the SVM classifier of the most easily separated class pair as each node. When there are fewer instances to be predicted, a part of the SODDAG-SVM structure passed by these instances is directly built for predicting the instances. When more instances need to be predicted, a complete SODDAG-SVM structure is first constructed and then is used to predict all the instances. Action recognition experiment is performed on the upper limb routine rehabilitation training samples of the Brunnstrom 4~5 stage, acquired using human body sensing technology. Results show that the accuracy reaches 95.49% which is higher than those of conventional decision directed acyclic graph (DDAG) and MaxWins methods. It is proved that the proposed method can effectively improve the accuracy of rehabilitation training action recognition.

Key words Upper limb rehabilitation training, action recognition, structure-optimized decision directed acyclic graph-support vector machine (SODDAG-SVM), multi-class classifier, binary classifier

Citation Zuo Guo-Yu, Xu Zhao-Kun, Lu Jia-Hao, Gong Dao-Xiong. A structure-optimized DDAG-SVM action recognition method for upper limb rehabilitation training. *Acta Automatica Sinica*, 2020, 46(3): 549–561

收稿日期 2017-12-23 录用日期 2018-08-27
Manuscript received December 23, 2017; accepted August 27, 2018

国家自然科学基金 (61873008, 61673003), 北京市自然科学基金 (418 2008), 北京工业大学智能制造领域大科研推进计划 (JZ0410012017 02) 资助

Supported by National Natural Science Foundation of China (61873008, 61673003), Beijing Natural Science Foundation (4182 008), and Beijing University of Technology Big Scientific Pro-

moting Plan on Intelligent Manufacturing (JZ041001201702)

本文责任编辑 白翔

Recommended by Associate Editor BAI Xiang

1. 北京工业大学信息学部 北京 100124 2. 计算智能与智能系统北京市重点实验室 北京 100124

1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124 2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124

随着世界各国老龄化问题的日益突出,脑卒中患者的数量不断增加。脑卒中是一种进展性慢性致残疾病^[1],85%的脑卒中患者在患病初期就有上肢功能障碍^[2],约30%~36%的脑卒中患者在发病6个月后仍遗留有上肢功能障碍,严重影响了他们的生活质量^[3]。大量研究结果表明,由于大脑的可塑性,康复训练可以恢复中风患者大部分的运动能力^[4]。传统的康复训练多是在理疗师和大型训练器械的帮助下,协助患者进行康复训练^[5]。这种方法虽可以有效地完成对患者的训练,但其成本高、自主性差、单调乏味,且难以对康复效果进行实时有效的测量和评价^[6]。随着人体传感技术的不断创新和发展,已有越来越多的学者将人体动作传感技术应用于脑卒中患者的康复训练^[7]。国内外已有不少研究证实,该方法对治疗肢体残疾患者的运动功能有很好的效果,尤其是能积极改善患者的心理和情感状态,让患者乐于接受康复训练,具有定量的评价体系也可为患者及医护人员提供患者的康复动作评估信息^[8-11]。即便如此,也并非所有康复阶段都适合采用这种方法。根据Brunnstrom分期理论,患者肢体运动功能的曲线恢复过程可分为6个阶段,其中在4~5阶段,患者开始脱离共同运动,出现分离的精细运动,肌张力逐渐恢复^[12]。这个阶段患者运动范围增大,而且可以脱离助力器械自主完成一些训练,此时使用人体传感技术对医护人员和患者提供动作评估信息就具有了很重要的作用。

进行康复训练评估的关键在于应用人体传感技术进行动作识别,即使用动作识别算法对患者正在做的康复训练动作进行识别,判断是否为当前康复训练要求的规定动作。若符合,初步判定患者所做的康复训练动作为合格,否则判定为不合格。

目前,人体动作识别主要分为基于视觉传感^[13]和基于可穿戴传感器^[14]的两大类方法。其中,基于视觉传感的动作识别方法受环境条件影响严重,且视觉传感模式产生的大数据量,与在动作识别任务中信息处理时对特征数据简化表示的约束之间,存在严重不对称的数据鸿沟。基于可穿戴传感器的动作识别方式通过固定在人体肢体上的传感器,对人体进行接触式测量,可在光线、角度和障碍物等外部条件受限的情况下稳定可靠地获取姿态数据,免于分布式视觉采集系统对空间环境的严格要求。随着无线传感器技术的发展,使用可穿戴传感器的动作识别也获得了较大优势,国内外很多机构也开展了基于可穿戴设备的人体动作识别研究^[15]。Foerster等^[16]将4个加速度计分别固定在胸、腕、大腿、小腿上,对坐、躺等9个动作进行了识别,其实验结果表明基于加速度计的运动检测是可靠的。Lee等^[17]

将单个加速度计放在背部,先将信号分为AC、DC两路,之后再对AC和DC信号细分,对跑、走等9个动作进行识别,得到的动作平均分类准确率达到95.1%。Karantonis等^[18]在腰部固定单个加速度计和陀螺仪传感模块,采用幅值与重力方向的夹角阈值来识别走路和跌倒,验证了基于加速度计的实时动作分类器的可行性。Khan等^[19]将一个加速度计固定在胸部,采用AR自回归模型系数、倾角和信号幅值区域作为特征,依据分层人工神经网络对3个静态动作(躺、坐、站)和4个动态动作(走、上楼、下楼、跑)进行了识别,平均准确率达到97.9%。Zhang等^[20]把单个九轴传感器固定在人体右髋关节前,通过随机投影方法对特征向量进行优化,并构建稀疏矩阵对9个动作进行识别,最高识别率达到了96.1%。Vital等^[21]使用FatoXtract可穿戴动作采集服,对一些相似动作(如刷牙和挥手、走路和迈步)进行识别,准确率和召回率都保持在85%左右。

在动作识别技术中,支持向量机(Support vector machine, SVM)由于具有很多优秀的特性,如很强的泛化能力,至今仍被广泛地采用^[22]。文献[21]的概率集成算法集成了SVM及朴素贝叶斯、神经网络三个分类器对动作进行识别分类。Wu等^[23]使用SVM对基于MMG信号的6类人体膝关节动作进行识别,平均准确率到达88%。Wang等^[24]基于SVM研究了一种集成学习算法,用于乳腺癌的诊断,减少了97.89%的诊断不一致率,提高了33.34%的诊断准确率。但在将SVM方法从解决二分类问题拓展到解决多分类问题时,常会出现存在不可分区域的情况。Platt等^[25]针对这一问题提出的决策有向无环图(Decision directed acyclic graph, DDAG)方法,可将不可分区域划归到具体的类别中,并可以降低分类的计算量。但DDAG方法构建的多分类器结构随机性较大,会将不可分区域随机划分到某些类别中,降低了DDAG多分类器的性能。

针对DDAG方法存在的问题,本文结合SVM方法,提出一种面向Brunnstrom 4~5期患者上肢康复训练的SODDAG-SVM(Structure-optimized decision directed acyclic graph-support vector machine)动作识别方法。该方法首先衡量多分类问题中各类对(class pair)的易被分离程度,之后将较易被分离的类对放在多分类器的较上层节点,降低不易被分离的类对对分类的影响,提高将不可分区域划分到正确类别的几率,从而提高多分类器的性能。本文先简要介绍支持向量机及多分类问题的基础理论,在分析DDAG层级结构对多分类器性能影响的问题后,详细描述所提出的SODDAG-SVM算法,

并在第3节中对 SODDAG-SVM 多分类器的构建过程进行介绍, 最后在采集到的上肢康复训练动作样本数据集上进行分类实验。

1 基础理论

支持向量机^[26] 最初用于解决二分类问题, 后来拓展到多分类问题上, 而在将二分类支持向量机拓展到多分类问题时, 解决方法并不唯一。

1.1 二分类支持向量机

支持向量机基本模型定义为特征空间上距离分类超平面间隔最大化的分类器. 设有 m 维输入 \mathbf{x}_i , $i = 1, 2, \dots, M$, 属于第1类或第2类, 则其对应标签为 $y_i = 1$ 或 $y_i = -1$, 其决策函数为

$$D(\mathbf{x}) = \mathbf{w}^t \mathbf{x} + b \quad (1)$$

其中, \mathbf{w} 是一个 m 维向量, b 是标量。

令式(1)中 $D(\mathbf{x}) = 0$, 即为分类超平面, 最小化式(2)得到最优分类超平面。

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^M \xi_i \quad (2)$$

$$\text{s.t. } y_i(\mathbf{w}^t \mathbf{x}_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, M \quad (3)$$

$$\xi_i \geq 0, \quad i = 1, 2, \dots, M \quad (4)$$

其中, $C > 0$ 称为惩罚参数, 是权衡边界最大化和分类误差最小化的参数. 满足式(3)等号条件的样本点称为支持向量. 式中, 当 C 值增大时, 对误分类的惩罚也增大, 反之对误分类的惩罚则减小。

为提高支持向量机解决非线性分类问题能力, 可以通过一个非线性变换将输入空间(欧氏空间 \mathbf{R}^n 或离散集合)映射到一个高维的特征空间(希尔伯特空间). 假设映射函数为 $g(\mathbf{x})$, 其在特征空间中的点乘可表示为 $H(\mathbf{x}, \mathbf{x}') = g(\mathbf{x})^t g(\mathbf{x}')$, $H(\mathbf{x}, \mathbf{x}')$ 称为核函数. 核函数中, 式(5)所示为常用的径向基核函数(Radial basis function, RBF)

$$H(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (5)$$

其中, $\gamma > 0$ 是控制斜率的参数。

1.2 多分类问题

多类分类问题在现实中广泛存在, 而且有很多不同的解决方法, 但大致可分为两类. 第1类为直接拓展方法, 将二分类方法进行拓展, 使其适合多分类问题; 第2类为分解与集成方法, 先将多分类问题分解成一组二分类问题, 之后应用集成策略集成各个二分类的结果, 从而得到多分类器的最终结果. Dietterich^[27] 的理论验证了第2类方法的优越性,

很多其他研究也表明分解与集成方法可以获得更好的多分类性能^[28-30]。

集成策略一般需要与分解策略匹配使用. 分解策略中, 一对一(One vs one, OVO)和一对多(One vs all, OVA)是最常使用的方法, OVO 总体上要优于 OVA 方法^[31-32]. OVO 和 OVA 方法可使用 MaxWins 投票方法作为集成策略, 但在采用 MaxWins 解决多分类问题时, 也会存在不可分区域问题。

图1所示为一个三类分类问题, 其中, $D_{ij}(\mathbf{x}) = 0$ 为类 i 和类 j 间的分类超平面. 假设 $V(i)$ 为类 i 的得票数, 若 $V(i) = n - 1$, 则所有与类 i 相关的二分类器都将实例 \mathbf{x} 预测为类 i ; 若 $V(i) \neq n - 1$, 说明存在与类 i 相关的二分类器误将 \mathbf{x} 预测为非类 i , 此时可能出现某些类得票数相同而造成 \mathbf{x} 不可分的情况. 当 $V(i) = 1, i = 1, 2, 3$ 时, 从图中可以看到, \mathbf{x} 将处于不可分的阴影区域。




图1 投票策略产生的不可分区域响

Fig. 1 An inseparable region in voting strategy

2 SODDAG-SVM 分类方法

2.1 DDAG 方法

为解决存在不可分区域的问题, 文献[26]提出了决策有向无环图(DDAG)方法. DDAG 的基本思想是: 从顶层节点开始, 沿有向无环图结构依次访问各个节点, 在最后的叶子节点返回对实例预测的结果. 在 DDAG 结构中, 每一个节点对应一个二分类器. DDAG 算法流程如算法1所示。

算法1. DDAG 算法

输入. $n(n-1)/2$ 个从训练集训练得到的二分类器以及实例 \mathbf{x} .

输出. DDAG 的结构, 以及对于实例 \mathbf{x} 的预测

结果.

步骤 1. 生成初始类别列表 $Cl = 1, 2, 3, \dots, n$.

步骤 2. 随机选择类别列表中的两个元素, 形成类对 (i, j) . 如果 x 被二分类器 D_{ij} 分到类 i 中, 则从列表中移除第 j 类, 否则移除第 i 类, 得到新的类别列表 Cl .

步骤 3. 如果在类别列表 Cl 中的元素多于 1 个, 则跳转回步骤 2, 否则将 x 分类为类别列表 Cl 中剩下的唯一一个类别并停止.

如果将图 1 中的三分类问题改用算法 1 描述的 DDAG 方法进行分类, 可以得到图 2 所示的一种分类结构示意图, 以及与之对应的如图 3 所示的分类效果. 图 2 中, \bar{i} 表示实例 x 被判别为不属于类 i , 图 3 将不可分区域归入了类 3 中. 可见 DDAG 方法可以消除图 1 中的不可分区域. 而且 DDAG 完成分类预测的所需时间也比投票策略短, 因为投票策略完成一次预测需要经过 $n(n-1)/2$ 个二分类器, 而 DDAG 完成每次预测只需经过 $n-1$ 个二分类器.




图 2 三分类器 DDAG 结构示意图

Fig. 2 A DDAG structure of a three-class classifier




图 3 消除了不可分区域的 DDAG 分类

Fig. 3 Elimination of inseparable region in a DDAG classifier

2.2 SODDAG-SVM 方法

在 DDAG 方法中, 由于顶节点和其他节点的位置顺序可以任意地选择, 这样会导致 DDAG 结构的随机性. 由图 2 和图 3 可以明显看出, 随机的有向无环图结构会将不可分区域归入随机的类别, 从而降低了 DDAG 的分类性能. 因此, 本文将针对上述 DDAG 方法存在的这一问题, 结合二分类 SVM 方法, 设计一种优化 DDAG 层级结构的 SODDAG-SVM 多分类方法, 以下将对其进行详细介绍.

把较易被分类的类对放在较上层的节点中, 一则 DDAG 在预测过程中只经过 $n-1$ 个二分类器, 将较易被分离的类对放在上层节点, 可以使分类过程不经过一些不易被分离的类对; 二则在下层节点中遇到不易被分离的类对时, 其分类边界已被上层节点得到的结果所限定, 这样可以提升多分类器的性能. 这里提出一种类对易被分离程度的概念, 对于一个由类 i 和类 j 构成的类对, 使用类 i 和类 j 间 SVM 分类器的泛化误差 E_{ij} 来表示该类对易被分离程度, 定义为

$$E_{ij} = \frac{SV_{ij}}{M_{ij}} \quad (6)$$

其中, SV_{ij} 是类 i 和类 j 间二分类器的支持向量个数, M_{ij} 是类 i 和类 j 的训练样本总数. 当 E_{ij} 越小时, 泛化误差越小, 泛化能力越强, 类对越易被分离; E_{ij} 越大, 泛化误差越大, 泛化能力越弱, 类对越不易被分离.

根据各个二分类器模型的泛化误差 E_{ij} , 可以得到如式 (7) 所示的类对泛化误差上三角矩阵 M_E

$$M_E = \begin{bmatrix} 10 & E_{12} & E_{13} & \cdots & E_{1n} \\ & 10 & E_{23} & \cdots & E_{2n} \\ & & 10 & \ddots & \vdots \\ & & & \ddots & E_{n-1,n} \\ & & & & 10 \end{bmatrix} \quad (7)$$

其中, 矩阵 M_E 的第 i 行第 j 列元素为类 i 和类 j 间 SVM 分类器的泛化误差 E_{ij} . 为方便后续计算, 这里将矩阵对角线元素设为 10. 矩阵 M_E 包含了各 SVM 二分类器的泛化能力信息, 以及 DDAG-SVM 算法中类别列表 Cl 所含的类别信息.

采用类对泛化误差上三角矩阵 M_E 可以方便地删减已被剔除的类别, 也能方便地在当前可被选取的二分类器中选出泛化误差最小的二分类器.

当待预测实例较少时, 可以在构建具体实例经过的部分有向无环图结构的同时, 对该实例进行预

测分类, 本文称这种方法为 SODDAG-SVM 预测算法, 其流程如算法 2 所示.

算法 2. SODDAG-SVM 预测算法

输入. $n(n-1)/2$ 个从训练集训练得到的二分类器, 以及实例 \mathbf{x} .

输出. 实例经过的部分 SODDAG 的结构, 以及对于实例 \mathbf{x} 的预测结果.

步骤 1. 使用各类对的二分类器模型的泛化误差 E_{ij} , 生成初始为 $n \times n$ 的泛化误差矩阵 M_E .

步骤 2. 选择泛化误差矩阵 M_E 中非零的最小元素, 其对应的行号 i 和列号 j 即为当前泛化误差最小的类对 (i, j) , 将该类对对应的二分类器 $D_{i,j}$ 作为下一个二分类节点.

步骤 3. 若 \mathbf{x} 被二分类器分到类 i 中, 则将矩阵 M_E 中的 j 行 j 列置为 0, 否则将 i 行 i 列置 0, 得到新的泛化误差矩阵 M'_E .

步骤 4. 若在泛化误差矩阵 M'_E 中值为 10 的元素多于一个, 则跳转回步骤 2, 否则将 \mathbf{x} 分类到泛化误差矩阵 M'_E 中值为 10 元素所对应的类别中并停止.

图 4 为采用 SODDAG-SVM 预测算法构建部分有向无环图结构并对实例进行预测的示意图.

为方便描述, 在图 4 中, 我们引入了各二分类器节点所对应的类别列表 Cl_n , 其所描述的信息包含在泛化误差矩阵中. 图中使用由深到浅的色块用于标识从根层级到叶子层级的 SODDAG-SVM 层级结构. 根据泛化能力对类别列表 Cl_n 中各类对的二分类器进行排序, 可以得到有序的 SVM 分类器列表:

$$D^1_{Cl_n}(\mathbf{x}), D^2_{Cl_n}(\mathbf{x}), D^3_{Cl_n}(\mathbf{x}), \dots$$

选择其中泛化能力最强的 SVM 分类器 $D^1_{Cl_n}(\mathbf{x})$ 作为当前第 n 层的节点, 并对实例进行二分类. 再根据该二分类结果, 从第 n 层的类别列表 Cl_n 中将不正确的类别剔除, 得到第 $n+1$ 层的类别列表 Cl_{n+1} , 再对第 $n+1$ 层做同样的操作, 以此类推, 可以得到图 4 左边的 SODDAG-SVM 部分结构, 每层中泛化能力最强的 SVM 分类器被选择为该层的节点.

当待预测的实例较多时, 由于算法 2 对每一个实例 \mathbf{x} 都需要进行 $n-1$ 次的分类器选择, 使计算变得较为复杂, 此时可在预测前构建完整的 SODDAG-SVM 有向无环图结构, 再对大量的实例进行预测.

在构建完整的 SODDAG-SVM 结构时, 先对所有的类对训练相应的 SVM 二分类器, 再评估出各个类对的易被分离程度, 并以此构建 M_E 矩阵. 之后根据 M_E 矩阵将泛化误差较小的类对放到较上层的节点中, 构建出一个有重复节点的 SODDAG-SVM 二叉树有向无环图结构. 我们称该方法为 SODDAG-SVM 完整结构的构建算法. 该算法是一种递归算法, 构建完整结构时需要从多分类器的根节点开始递归地使用, 算法 3 描述了递归构建结构的过程.

算法 3. SODDAG-SVM 完整结构的递归构建算法

输入. 类对泛化误差上三角矩阵 M_E .

输出. SODDAG-SVM 完整结构.

步骤 1. 选择泛化误差矩阵 M_E 中非零的最小元素, 其对应的行号 i 和列号 j 即为当前泛化误差最小的类对 (i, j) , 将该类对间的二分类器 $D_{i,j}$ 作为当前的二分类节点.

步骤 2. 进入当前节点的左分支节点, 此时当前




图 4 SODDAG-SVM 预测算法示意图

Fig. 4 Diagram of SODDAG-SVM prediction algorithm

节点的预测结果为 \bar{j} , 于是将矩阵中的 j 行 j 列置为 0, 得到新的泛化误差矩阵 M'_E .

步骤 3. 若在泛化误差矩阵 M'_E 中值为 10 的元素多于 1 个, 则递归执行算法 3, 并令类对泛化误差上三角矩阵 $M_E = M'_E$; 否则令当前节点的左分支节点为类别 i .

步骤 4. 进入当前节点的右分支节点, 此时当前节点的预测结果为 \bar{l} , 于是将矩阵 M_E 中的 i 行 i 列置为 0, 得到新的泛化误差矩阵 M''_E .

步骤 5. 若在泛化误差矩阵 M''_E 中值为 10 的元素多于 1 个, 则递归执行算法 3, 并令类对泛化误差上三角矩阵 $M_E = M''_E$; 否则令当前节点的右分支节点为类别 j .

步骤 6. 若为首次调用该算法, 则结束构建并得到 SODDAG-SVM 的完整结构; 否则返回该次算法被调用的位置.

在算法 3 的基础上, 进一步合并相同节点, 可以得到更加简洁的 SODDAG-SVM 有向无环图结构. 由于未合并重复节点的二叉树结构更具一般性, 这里以该结构为例进行说明, 图 5 为应用算法 3 得到的 SODDAG-SVM 完整结构示意图.

为方便描述, 在图 5 中同样引入了各二分类器节点所对应的类别列表 Cl_n^p . 图中的 $D_{Cl_n^p}^*(\mathbf{x})$ 是在当前节点所对应 Cl_n^p 列表所含各类对中泛化能力最强的 SVM 二分类器, 也就是根据当前节点所对应的 M_E 矩阵来选择泛化能力最强的二分类器. p 为所在结构的层数 ($0, 1, 2, \dots, p, \dots, P$), n 为 p 层中从左数第几个节点 ($1, 2, 3, \dots, n, \dots, N$).

图中, 不同灰度的色块表示其中的节点位于不同的类别列表和不同的 M_E 矩阵之中. 如图 5 所示, 根节点 $D_{Cl_1^0}^*(\mathbf{x})$ 对应了初始类别列表 $Cl_1^0 = \{a, b, c, \dots\}$ 和初始的 M_E 矩阵, 其中包含所有的类对. 若根节点将实例判别为 b , 则将 b 类

从类别列表 $Cl_1^0 = \{a, b, c, \dots\}$ 及相应的 M_E 矩阵中剔除, 得到根节点左分支节点所处的类别列表 $Cl_1^1 = \{a, b, c, \dots\}$, 从中选出泛化能力最强的 $D_{Cl_1^1}^*(\mathbf{x})$ 作为该节点的二分类器. 同理, 可以得到其他节点所处的类别列表、 M_E 矩阵及相应的最优 SVM 二分类器.

算法 1 所示的 SODDAG-SVM 预测算法和算法 2 所示的 SODDAG-SVM 完整结构递归构建算法是在本文构建的 SODDAG-SVM 结构核心思想的基础上所提出的两种具体算法. 其一是在对每一个实例进行预测时都使用 SODDAG-SVM 构建思想, 依据各实例情况来规划其要经过的二分类器节点; 另一则是在对实例进行预测之前, 使用 SODDAG-SVM 构建思想, 对所有可能的情况进行规划, 在进行预测前得到完整的 SODDAG-SVM 结构, 之后再代入实例进行预测. 两种预测算法采用同样的多分类器构建思想, 两者的预测结果相同, 只是在面对不同情况的问题时效率不同.

就两种算法的具体效率而言, 其不同点主要在于两种算法所含的二分类器节点的数量不同, 因为每一个二分类器节点都需要通过构建式 (7) 的类对泛化误差上三角矩阵 M_E 来选取. 在 SODDAG-SVM 预测算法中所含的二分类器节点为 $n \times (l - 1)$ 个, 而在 SODDAG-SVM 完整结构构建算法中所含的二分类器节点为 $2^{l-1} - 1$ 个, 其中 n 表示待预测样本集中样本的数量, l 表示总类别数量. 当选择所含二分类器节点数量少的算法时, 算法效率会更高一些.

3 方法实现

本节首先对 Brunnstrom 4~5 阶段康复训练动作样本数据的获取方法及其构成进行描述, 然后介




图 5 SODDAG-SVM 完整结构示意图

Fig. 5 Diagram of the complete structure of SODDAG-SVM

绍 SODDAG-SVM 多分类器的具体实现过程.

3.1 动作信息获取

在人体动作识别研究中, 由于缺乏统一的动作数据集, 很多研究者通常在各自设计的数据集上验证动作识别方法^[11-12]. 本文通过文献 [14] 研制的可穿戴式人体动作采集系统获取康复训练动作样本数据, 每个数据都包含了人体各个关节的动作信息. 该系统由多个惯性测量单元组成, 每个测量单元由九轴的惯性测量系统构成, 包括三轴加速度计、陀螺仪和磁力计. 融合加速度计和磁力计信息, 得到陀螺仪的误差, 再通过补偿器, 将陀螺仪误差与陀螺仪原始数据进行融合, 得到准确的关节角速度值, 进而获得关节角度值. 为保证对原始姿态解算的实时性, 该采集系统选用计算量较小且不存在万向锁的四元数来表示人体动作数据. 由四元数表示的人体动作信息不能直接用于动作识别, 需要将初步解算得到的四元数人体动作信息进一步解算为人体各关节的动作角度信息, 从而最终得到人体上肢颈关节、腰关节和肩关节的俯仰、偏航、横滚角以及肘关节的俯仰、横滚角.

本文选取 Brunnstrom 4~5 阶段中用于训练肩关节、肘关节、腰关节及腰肩关节协作的常用坐姿训练动作来建立动作样本集, 包括坐姿双臂握手左右摆动一次 ($m1$), 坐姿双臂握手向上屈曲伸直一次 ($m2$), 坐姿双臂握手举起打转一次 ($m3$), 坐姿双臂握手伸直体左前屈 ($m4$)、体前屈 ($m5$)、体右前屈 ($m6$). 所有动作的起始动作均为坐姿上臂握手伸直于胸前. 6 个动作中的握手动作又称为 Bobath 握手, 是神经生理疗法中一种常用的方法, 广泛应用于脑卒中的临床康复治疗中, 可以防止手的屈曲痉挛, 在前臂伸展时有助于抑制屈肘肌群的痉挛, 在上臂屈曲练习中可防止肩关节继发性活动受限, 适宜应用于大部分上肢康复训练中.

图 6 为起始动作及 6 组动作的示意图, 其中左 1 为所有动作的起始动作, 其他从左到右依次为 $m1$, $m2$, $m3$, $m4$, $m5$, $m6$ 动作.




图 6 起始动作及 6 组动作示意图

Fig. 6 Start action and six types of training actions

3.2 多分类器构建

首先根据所采集数据以及各类动作的特点提取有效的特征值来构建各二分类器, 之后对各二分类器的参数及特征子集进行寻优和选择, 以优化各二分类器, 再根据各二分类器的泛化性能构造泛化误差矩阵 M_E , 最后根据矩阵 M_E 构建 SODDAG-SVM 多分类器的完整结构.

1) 特征值提取

有效特征的提取是构建分类器的前提. 由上节所述方法采集的人体上肢 13 路角度数据, 分别提取平均值、标准差、峰峰值以及过均值点四个时域参数作为样本特征. 平均值 $mean$ 表征各路角度数据的均值位置, 标准差 std 表征各路角度数据偏离平均值的程度, 峰峰值 ppv 表征各路角度数据的变化范围, 以及过均值点 $aboveMean$ 分别表示为

$$mean = \frac{1}{n} \sum_{i=1}^n x(i) \quad (8)$$

$$std = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})^2} \quad (9)$$

$$ppv = \max_i x_i - \min_i x_i \quad (10)$$

$$aboveMean = \sum_{i=1}^n \mathbb{I}(x_i > \bar{x}) \quad (11)$$

其中, $\mathbb{I}(\cdot)$ 是指示函数, 当括号内条件成立时取值为 1.

我们按左肩关节的俯仰、偏航、横滚角, 左肘关节的俯仰、横滚角, 右肩关节的俯仰、偏航、横滚角, 右肘关节的俯仰、横滚角, 腰部关节的俯仰、偏航、横滚角顺序, 从 1 到 13 进行编号, 构建出下式所示的特征向量

$$\mathbf{x} = [mean1, std1, ppv1, aboveMean1, \dots, mean13, std13, ppv13, aboveMean13] \quad (12)$$

2) 二分类器的参数选择

使用常用且参数复杂度较低的 RBF 核函数作为 SVM 二分类器的核函数. 以 RBF 为核的 SVM 分类器涉及 C, g 两个参数的寻优问题, 其中的 C 即是式 (2) 中的惩罚因子 C , g 又称为 γ , 即为式 (5) 中的 γ 参数.

将动作样本集中的 m_1, m_2, \dots, m_6 六类动作依次命名为类 1, 类 2, \dots , 类 6, 采用 OVO 策略分解该六类分类问题, 可以得到如下所示的 15 个 SVM 二分类器:

$$1v2, 1v3, 1v4, 1v5, 1v6, 2v3, 2v4, \dots, 5v6$$

分别对这 15 个 SVM 二分类器使用遗传算法 (Genetic algorithm, GA) 对其 C, g 参数进行寻优, 初步构建各类对的二分类器. GA 算法的使用可以在更大范围内且不必遍历所有参数点的情况下找到全局最优解.

3) 二分类器的特征子集选择

对参数 C, g 进行寻优可以提升 SVM 分类器的性能, 但 SVM 的分类性能和泛化能力还会受到高维度样本向量的影响. 特征选择方法可以有效剔除冗余特征, 减少模型复杂度, 避免过拟合现象, 降低计算量, 提高支持向量机的分类性能和泛化能力. 以样本 m_2 类动作和 m_4 类动作为例, 该二分类器在特征选择过程中, 不同特征数量的特征子集所对应的 SVM 二分类器的分类准确率如图 7 所示. 可以看到, 不经过特征选择时特征集合含有 52 个特征, 此时所对应的 SVM 分类准确率为 83.88%, 并非最优性能. 经特征选择后可将分类准确率提升至 100%, 并将特征子集中特征数量降低到 6 维, 能有效地提高 SVM 分类器的性能, 并降低数据的维度.




图 7 特征选择对于 SVM 二分类器性能的影响
Fig. 7 Effect of feature selection on the accuracy of SVM binary classifier

为了得到更好的特征选择效果, 本文没有针对整个多分类问题进行特征选择, 而是对构成多分类问题的各二分类问题进行特征选择. 由于涉及 15 个 SVM 二分类器, 不同分类器针对不同的类对和不同的样本, 对各个特征的敏感度完全不同, 故需要对各个 SVM 二分类器分别进行特征选择, 来获得更好的特征选择效果.

特征选择方法包括特征子集搜索策略和特征子集性能评价准则两个主要部分^[33]. 本文采用顺序前向搜索 (Sequential forward search, SFS) 方法作为特征子集搜索策略, 使用 Filter 和 Wrapper 算法相结合的混合评价准则为特征子集性能评价准则. 在 Filter 方法中使用特征子集区分度评价准则 (Discernibility of feature subsets, DFS)^[34] 来衡量特征子集类间区分能力, 并选出各维度下当前最优的特征子集; 在 Wrapper 方法中使用 SVM 二分类器来进一步评估各维度下最优特征子集的效果, 并得到最终的最优特征子集.

本文所采用的特征选择算法中使用了 SVM 二分类器来测试各个特征候选子集的性能, 所以需先对各类对分类器的 C, g 参数进行寻优, 然后在特征选择中应用这些参数, 可以更好地优化各二分类器, 达到更好的分类效果.

4) 二分类器组合为多分类器

通过上述三个步骤, 构建并优化了各个二分类器. 之后由式 (6) 得到各二分类器的泛化误差, 再如式 (7) 构造类对泛化误差上三角矩阵 M_E . 当待预测实例较少时, 应用算法 2 构建部分多分类结构并对实例进行预测; 当待预测实例较多时, 应用算法 3, 先构建完整的 SODDAG-SVM 结构, 再使用该完整结构对所有待预测实例进行预测.

4 实验与分析

本节将使用第 3.2 节所述的 SODDAG-SVM 多分类器构建方法, 首先对各 SVM 二分类器的 C, g 参数及特征子集寻优结果进行分析和讨论, 再对 SODDAG-SVM 多分类器的性能与 DDAG-SVM 方法和 MaxWins-SVM 方法的性能进行对比.

为了使实验数据具有随机性, 将采得的 1200 个样本顺序随机打乱, 每一类依次逐个添加到 5 个空的样本集合中, 将采得样本随机均匀地划分成 5 份. 以 4 份样本作为训练集, 另一份样本作为测试集, 从第一份样本开始, 依次作为测试集, 其余作为训练集, 完成 5 次实验, 对 5 次实验的准确率取平均值, 以进行 5 折交叉验证.

4.1 二分类器的 C, g 参数寻优

实验使用 GA 方法, 在每次实验的训练集上寻

找最高 SVM 分类准确率的 C, g 参数组合. 由于 GA 是随机优化算法, 故对每个 SVM 二分类器进行 10 次 GA, 使用每个类对所对应的训练集中的两组动作样本, 并将其按比例随机分为 5 组, 每次求得的适应度为在训练集上 5 折交叉验证所得到的分类准确率, 取其中最高适应度的 C, g 参数的均值为对应 SVM 二分类器的 C, g 参数.

不同训练集上的各二分类器经 GA 寻优后, 得到的最佳 C, g 值略有不同, 但最高分类准确率基本相同. 表 1 列出了第 1 次实验训练集上各二分类器的最优分类准确率以及对应的最优参数.

4.2 二分类器特征子集寻优

实验采用第 3.2 节中所提的 DFS 算法, 并结合 SFS 方法, 对 15 个 SVM 二分类器分别进行特征选择, 各分类器参数则使用上一节中在各训练集上得到的分类器的最优 C, g 参数. 由于在 Wrapper 方法中需要使用二分类器的分类准确率来评价特征子集的性能, 故在每次实验中都将在训练样本集随机均匀地分成 5 份, 再使用五折交叉验证得到的二分类器准确率来评价并选出最优的特征子集. 5 次实验中, 从训练集上选出的最优特征子集相同, 但最优准确率会稍有差异. 表 2 汇总了全部 15 个 SVM 二分类器的最优特征子集所包含的特征, 以及该特征子

集在 5 个测试集上分类准确率的平均值. 为表述方便, 表 2 中将式 (12) 中的特征按先后顺序分别编号

表 1 C, g 参数寻优结果

Table 1 Optimization results of the parameters of C, g

类对	最优 C	最优 g	最优准确率 (%)
1v2	0.009793572	0.0022394	100
1v3	0.33971	1.08×10^6	100
1v4	1	9.73×10^6	95.5517
1v5	0.613049119	0.001941097	89.6552
1v6	1.10×10^6	0.00721982	95.4371
2v3	1	0.000019687	88.6836
2v4	0.023029107	0.019702158	83.8836
2v5	0.967574582	0.003192183	100
2v6	1	7.00×10^3	100
3v4	0.5	0.000033106	90
3v5	0.25	6.03×10^6	96.6689
3v6	1	0.000047963	86.6545
4v5	0.26493253	0.008829793	83.3582
4v6	0.825159853	0.020969172	88.6883
5v6	3.1249	0.000052136	86.6667

表 2 特征子集选择结果

Table 2 Feature subset selection results

类对	最优特征子集	测试集准确率 (%)
1v2	全部特征	100
1v3	全部特征	100
1v4	16, 1, 38, 25, 29, 7, 11, 20, 33, 50, 17, 30, 47	100
1v5	26, 39, 1	95.4767
1v6	26, 37	95
2v3	37, 24, 46	100
2v4	16, 29, 47, 37, 24, 21	100
2v5	21, 16, 29, 47, 34, 50, 37, 24, 46, 39, 26, 43, 13, 1, 52, 25, 32, 38, 45, 19, 4, 11, 41, 20, 28, 15, 42	100
2v6	39, 37, 24, 47, 50, 26, 21	100
3v4	37, 46, 42	94.6536
3v5	27, 14, 46, 42, 39, 26, 21, 17, 41, 13, 51, 30, 50, 16, 8, 7, 32, 19, 45	95.3467
3v6	13, 39, 26, 46, 17, 30, 42	100
4v5	29, 16, 39, 26, 19	100
4v6	39, 16, 26, 13, 29, 24	100
5v6	16	100

为 1, 2, 3, ..., 52.

4.3 多分类实验

根据第 4.1 节和第 4.2 节中得到的各训练集上各 SVM 二分类器对应的最优 C, g 参数及最优特征子集, 分别在各训练集上训练每一个二分类器, 以此得到各训练集上的 M_E 矩阵.

由于待预测的测试集样本较多, 又为能更好地说明 SODDAG-SVM 结构的优点, 故这里可按第 3.4 节所述, 由各训练集上 M_E 矩阵应用算法 3, 先得到完整的 SODDAG-SVM 结构, 再代入待预测实例进行预测. 各训练集上的 M_E 矩阵中各元素数值稍有不同, 但是类对二分类器泛化能力的排序相同, 所以, 在 5 次实验的训练集上所构建的 SODDAG-SVM 结构都一样.

对于多分类问题, 由于 DDAG 的结构存在着多种可能性, 所以我们使用 DDAG-SVM 对划分好的 5 份均匀随机样本进行 1000 次 5 折交叉验证实验, 并计算出其准确率的最大值、最小值及平均值. 由于本文提出的 SODDAG-SVM 和 MaxWins-SVM 方法框架结构没有随机性, 因此都只进行一次 5 折交叉验证.

表 3 分别列出了 SODDAG-SVM、DDAG-SVM 和 MaxWins-SVM 方法的分类准确率. 由于 SODDAG-SVM 和 MaxWins-SVM 分类器所得结果唯一, 表中未列出最大值和最小值. 由表 3 可见, MaxWins-SVM 的投票集成策略比 DDAG-SVM 最小准确率高 1.21%, 达不到 DDAG 的平均准确率, 而 SODDAG 的分类准确率比 DDAG 平均准确率高 3.4%, 比 DDAG 的最小准确率高 5.66%. 可见, 对于 Brunnstrom 4~5 阶段上肢康复训练动作的分类问题, 本文提出的 SODDAG-SVM 方法能有效提高分类的准确率.

表 3 分类准确率对比 (%)
Table 3 Comparison of classification accuracy (%)

	DDAG	SODDAG	MaxWins
平均值	92.09	95.49	91.04
最大值	96.89	/	/
最小值	89.83	/	/

表 4 为上述 3 种方法的时间开销情况. 可以发现, SODDAG-SVM 和 DDAG-SVM 方法的时间开销均少于 MaxWins-SVM 方法, SODDAG-SVM 则略多于 DDAG-SVM 方法.

实验中, 各训练集上的 M_E 矩阵中类对二分类

器泛化能力的排序相同, 其顺序为

表 4 时间开销对比 (s)
Table 4 Comparison of time cost (s)

	DDAG	SODDAG	MaxWins
时间	0.7459	1.0167	1.5723

$$3v6 > 4v6 > 2v3 > 4v5 > 1v3 > 1v2 > 1v4 > 2v4 > 2v6 > 2v5 > 5v6 > 1v5 > 1v6 > 3v5 > 3v4$$

为进一步说明 SODDAG-SVM 结构的特点, 表 5~9 分别列出了 SODDAG-SVM, 以及会出现误分类的 1v5、1v6、3v4、3v5 类对的各自混淆矩阵, 图 8 所示为构建的 SODDAG-SVM 完整结构图.

表 5 SODDAG-SVM 混淆矩阵
Table 5 SODDAG-SVM confusion matrix

类别	1	2	3	4	5	6
1	180	0	0	0	12	8
2	0	200	0	0	0	0
3	0	0	182	9	9	0
4	0	0	6	194	0	0
5	3	0	4	0	193	0
6	3	0	0	0	0	197

表 6 类对 1v5 混淆矩阵
Table 6 1v5 class pair confusion matrix

类别	1	5
1	186	14
5	4	196

表 7 类对 1v6 混淆矩阵
Table 7 1v6 class pair confusion matrix

类别	1	6
1	187	13
6	7	193

表 8 类对 3v4 混淆矩阵
Table 8 3v4 class pair confusion matrix

类别	3	4
3	191	9
4	12	188




图 8 SODDAG-SVM 完整结构图

Fig. 8 Complete structure of SODDAG-SVM




图 9 消除不可分区域示意图

Fig. 9 Inseparable region elimination diagram

表 9 类对 3v5 混淆矩阵
Table 9 3v5 class pair confusion matrix

类别	3	5
3	190	10
5	9	191

对比表 7 和表 5 可以看出, 在表 7 所示类对 1v6 的分类结果中, 类 6 样本被错分到类 1 的情况占类 6 总样本数量的 3.595%。而经过 SODDAG-SVM 多分类器后, 由表 5 可以看出, 该错分情况占类 6 总样本数量的比重降低到了 1.5%。由图 8 所示 SODDAG-SVM 结构可以发现, 第 6 类样本经过根节点, 根节点的右子节点后都会来到图 8 的第 3 层右起第一个节点中, 之后被 1v2 分类器分开, 经过 5v6 分类器或者 2v6 分类器后分别来到 1v6 或者 5v6 分类器节点。1v2 分类器将部分会被 1v6 分类器误分的样本分入了 5v6 分类器中, 降低了误分率, 图 9 所示为分类过程示意图。首先进行 1v2 间的

分类, 得到图 9(a) 图所示结果, 再经过 2v6 及 1v6 间分类器, 得到图 9(b) 和 9(c) 所示结果。可以看出, 不可分区域中的类 6 样本被正确划分到类 6 中。若将泛化能力较差的 1v2 分类器和泛化能力较高的 1v6 分类器调换, 则错分率无法降低。

同理, 表 7 中类 1 样本误分为类 6、表 8 中类 4 样本误分为类 3、表 9 中类 5 样本误分为类 3 等情况, 都受到 SODDAG-SVM 结构中较上层节点分类器的引导, 使部分样本避开了泛化能力低的分类器, 从而降低了误分率。

5 结束语

本文针对上肢康复训练系统评估方法中核心的动作识别问题, 提出了一种 SODDAG-SVM 多分类算法。采用该算法在 Brunnstrom 4~5 阶段 6 个常用坐姿上肢康复训练动作数据集上进行了分类实验, 结果表明, 采用本文方法构建的多分类器结构可以有效地降低泛化能力较差的二分类器对多分类器性

能的影响,提高了多分类问题的分类准确率.在本文方法的实现过程中,发现所选用的DFS特征选择方法,未能完全将已选特征和候选特征对分类的联合贡献引入特征子集的评价准则.下一步,我们将针对该问题展开研究,以进一步提升对各二分类器性能的优化,从而最终提升多分类器的性能.


References

- Alamri F F, Al Shoyaib A, Biggers A, Jayaraman S, Guindon J, Karamyan V T. Applicability of the grip strength and automated von Frey tactile sensitivity tests in the mouse photothrombotic model of stroke. *Behavioural Brain Research*, 2018, **336**: 250–255
- Saposnik G, Teasell R, Mamdani M, Hall J, McIlroy W, Cheung D, et al. Effectiveness of virtual reality using Wii gaming technology in stroke rehabilitation: a pilot randomized clinical trial and proof of principle. *Stroke*, 2010, **41**(7): 1477–1484
- Kwakkel G, Kollen B J, van der Grond J, Prevo J H. Probability of regaining dexterity in the flaccid upper limb: impact of severity of paresis and time since onset in acute stroke. *Stroke*, 2003, **34**(9): 2181–2186
- Mancisidor A, Zubizarreta A, Cabanes I, Bengoa P, Jung J H. Kinematical and dynamical modeling of a multipurpose upper limbs rehabilitation robot. *Robotics and Computer-Integrated Manufacturing*, 2018, **49**: 374–387
- Liang Ming, Dou Zu-Lin, Wang Qing-Hui, Xiong Wei, Zheng Ya-Dan, Chen Ying-Bei, et al. Application of virtual reality technique in rehabilitation of hemiplegic upper extremities function of stroke patients. *Chinese Journal of Rehabilitation Medicine*, 2013, **28**(2): 114–118
(梁明, 窦祖林, 王清辉, 熊巍, 郑雅丹, 陈颖蓓, 等. 虚拟现实技术在脑卒中患者偏瘫上肢功能康复中的应用. *中国康复医学杂志*, 2013, **28**(2): 114–118)
- Trombetta M, Bazzanello Henrique P P, Brum M R, Colussi E L, De Marchi A C B, Rieder R. Motion Rehab AVE 3D: a VR-based exergame for post-stroke rehabilitation. *Computer Methods and Programs in Biomedicine*, 2017, **151**: 15–20
- Li Ya-Nan, Zuo Guo-Kun, Cui Zhi-Qin, Xu Jia-Lin. Application progress of virtual reality technology in rehabilitation training. *Chinese Journal of Rehabilitation Medicine*, 2017, **32**(9): 1091–1094
(李雅楠, 左国坤, 崔志琴, 徐佳琳. 虚拟现实技术在康复训练中的应用进展. *中国康复医学杂志*, 2017, **32**(9): 1091–1094)
- Gu Ying, Tian Li-Hua, Chen Hong. Application of virtual reality training system and rehabilitation operation in upper limb dysfunction of hemiplegic patients. *Chinese Journal of Rehabilitation Medicine*, 2011, **26**(6): 579–581
(顾莹, 田利华, 陈红. 虚拟现实训练系统和康复作业治疗在偏瘫患者上肢功能障碍中的应用. *中国康复医学杂志*, 2011, **26**(6): 579–581)
- Mouawad M R, Doust C G, Max M D, McNulty P A. Wii-based movement therapy to promote improved upper extremity function post-stroke: a pilot study. *Journal of Rehabilitation Medicine*, 2011, **43**(6): 527–533
- Burdea G C, Cioi D, Martin J, Fensterheim D, Holenski M. The Rutgers Arm II rehabilitation system — a feasibility study. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2010, **18**(5): 505–514
- Park D S, Lee D G, Lee K, Lee G. Effects of virtual reality training using Xbox kinect on motor function in stroke survivors: a preliminary study. *Journal of Stroke and Cerebrovascular Diseases*, 2017, **26**(10): 2313–2319
- Suo Jian-Jun, Yang Hong-Qi. Clinical observation of Brunnstrom technology in treatment of cerebral infarction patients with hemiplegia. *Chinese and Western Medicine Journal of Cardiovascular and Cerebrovascular Diseases*, 2017, **15**(11): 1395–1398
(锁建军, 杨红旗. Brunnstrom 技术治疗脑梗死偏瘫病人临床观察. *中西医结合心脑血管病杂志*, 2017, **15**(11): 1395–1398)
- Guan Qiu-Ju, Luo Xiao-Mu, Guo Xue-Mei, Wang Guo-Li. Compressive infrared classification of human motion using HMM. *Acta Automatica Sinica*, 2017, **43**(3): 398–406
(关秋菊, 罗晓牧, 郭雪梅, 王国利. 基于隐马尔科夫模型的人体动作压缩红外分类. *自动化学报*, 2017, **43**(3): 398–406)
- Zuo Guo-Yu, Yu Shuang-Yue, Gong Dao-Xiong. Operator attitude algorithm for telerobotic nursing system. *Acta Automatica Sinica*, 2016, **42**(12): 1839–1848
(左国玉, 于双悦, 龚道雄. 遥操作护理机器人系统的操作者姿态解算方法研究. *自动化学报*, 2016, **42**(12): 1839–1848)
- Yurtman A, Barshan B. Activity recognition invariant to sensor orientation with wearable motion sensors. *Sensors*, 2017, **17**(8): Article No. 1838
- Foerster F, Smeja M, Fahrenberg J. Detection of posture and motion by accelerometry: a validation study in ambulatory monitoring. *Computers in Human Behavior*, 1999, **15**(5): 571–583
- Lee S H, Park H D, Hong S Y, Lee K J, Kim Y H. A study on the activity classification using a triaxial accelerometer. In: Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Cancun, Mexico: IEEE, 2003. 2941–2943
- Karantonis D M, Narayanan M R, Mathie M, Lovell N H, Celler B G. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE Transactions on Information Technology in Biomedicine*, 2006, **10**(1): 156–167
- Khan A M, Lee Y K, Lee S Y, Kim T S. A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer. *IEEE Transactions on Information Technology in Biomedicine*, 2010, **14**(5): 1166–1172
- Zhang M, Sawchuk A A. Human daily activity recognition with sparse representation using wearable sensors. *IEEE Journal of Biomedical and Health Informatics*, 2013, **17**(3): 553–560
- Vital J P M, Faria D R, Dias G, Couceiro M S, Coutinho F, Ferreira N M F. Combining discriminative spatiotemporal features for daily life activity recognition using wearable motion sensing suit. *Pattern Analysis and Applications*, 2017, **20**(4): 1179–1194

- 22 Ghaddar B, Naoum-Sawaya J. High dimensional data classification and feature selection using support vector machines. *European Journal of Operational Research*, 2018, **265**(3): 993–1004
- 23 Wu H F, Wang D Q, Huang Q, Gao L F. Real-time continuous recognition of knee motion using multi-channel mechanomyography signals detected on clothes. *Journal of Electromyography and Kinesiology*, 2018, **38**: 94–102
- 24 Wang H F, Zheng B C, Yoon S W, Ko H S. A support vector machine-based ensemble algorithm for breast cancer diagnosis. *European Journal of Operational Research*, 2018, **267**(2): 687–699
- 25 Platt J C, Cristianini N, Shawe-Taylor J. Large margin DAGs for multiclass classification. *Advances in Neural Information Processing Systems*, 1999, **12**(3): 547–553
- 26 Vapnik V N. An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 1999, **10**(5): 988–999
- 27 Dietterich T G. Ensemble methods in machine learning. In: *Proceedings of the 1st International Workshop on Multiple Classifier Systems*. Cagliari, Italy: Springer-Verlag, 2000. 1–15
- 28 Garcia L P F, Sáez J A, Luengo J, Lorena A C, de Carvalho A C P L F, Herrera F. Using the one-vs-one decomposition to improve the performance of class noise filters via an aggregation strategy in multi-class classification problems. *Knowledge-Based Systems*, 2015, **90**: 153–164
- 29 Krawczyk B, Woźniak M, Herrera F. On the usefulness of one-class classifier ensembles for decomposition of multi-class problems. *Pattern Recognition*, 2015, **48**(12): 3969–3982
- 30 Sesmero M P, Alonso-Weber J M, Gutierrez G, Ledezma A, Sanchis A. An ensemble approach of dual base learners for multi-class classification problems. *Information Fusion*, 2015, **24**: 122–136
- 31 Montañés E, Barranquero J, Díez J, del Coz J J. Enhancing directed binary trees for multi-class classification. *Information Sciences*, 2013, **223**: 42–55
- 32 Hsu C W, Lin C J. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*, 2002, **13**(2): 415–425
- 33 Xie J Y, Wang C X. Using support vector machines with a novel hybrid feature selection method for diagnosis of erythematous-squamous diseases. *Expert Systems with Applications*, 2011, **38**(5): 5809–5815
- 34 Xie Juan-Ying, Xie Wei-Xin. Several feature selection algorithms based on the discernibility of a feature subset and support vector machines. *Chinese Journal of Computers*, 2014, **37**(8): 1704–1718
(谢娟英, 谢维信. 基于特征子集区分度与支持向量机的特征选择算法. *计算机学报*, 2014, **37**(8): 1704–1718)



左国玉 博士, 北京工业大学信息学部副教授. 主要研究方向为智能技术系统, 机器人学习和机器人控制. 本文通信作者. E-mail: zuoquoyu@bjut.edu.cn
(ZUO Guo-Yu Ph. D., associate professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers intelligent technology systems, robot learning, and robot control. Corresponding author of this paper.)



徐兆坤 北京工业大学信息学部硕士研究生. 主要研究方向为模式识别和机器学习. E-mail: 21xzk@sina.com.cn
(XU Zhao-Kun Master student at the Faculty of Information Technology, Beijing University of Technology. His research interest covers pattern recognition and machine learning.)



卢佳豪 北京工业大学信息学部硕士研究生. 主要研究方向为模式识别和机器学习. E-mail: ljh_lujiahao@163.com
(LU Jia-Hao Master student at the Faculty of Information Technology, Beijing University of Technology. His research interest covers pattern recognition and robot learning.)



龚道雄 博士, 北京工业大学信息学部副教授. 主要研究方向为计算智能与机器人学. E-mail: gongdx@bjut.edu.cn
(GONG Dao-Xiong Ph. D., associate professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers computational intelligence and robotics.)