

# 基于 K-SVD 的最大似然稀疏表示体域网动作分类算法<sup>①</sup>

王佳境, 吴建宁, 凌 雲, 李杰成

(福建师范大学 数学与信息学院, 福州 350007)

通讯作者: 吴建宁, E-mail: jianningwu@fjnu.edu.cn

**摘 要:** 为有效提高体域网动作分类性能, 本文提出了一种基于 K-SVD 的最大似然稀疏表示体域网动作分类算法. 该算法首先基于 K-SVD 优化学习算法, 将不同动作模式训练样本按其所属类别分组优化训练, 避免各类样本数据训练时相互干扰, 得到不同动作模式类别所属的子字典, 然后将其拼合构成一个完整字典, 准确稀疏表示测试样本, 最后基于最大似然稀疏模型准确估计稀疏表示系数残差, 并得到测试样本所属类别. 实验结果表明, 本文所提算法能够获得最优字典, 基于最大似然稀疏表示可准确估计测试动作样本稀疏表示残差. 所提算法识别率明显优于传统稀疏表示动作分类算法, 可有效提高体域网动作模式分类性能.

**关键词:** 体域网; 动作识别; 稀疏表示; 过完备字典; 最大似然模型

引用格式: 王佳境, 吴建宁, 凌雲, 李杰成. 基于 K-SVD 的最大似然稀疏表示体域网动作分类算法. 计算机系统应用, 2018, 27(2): 144-150. <http://www.c-s-a.org.cn/1003-3254/6180.html>

## Maximum Likelihood Sparse Representation Activity Recognition Algorithm Based on K-SVD in Body Sensor Networks

WANG Jia-Jing, WU Jian-Ning, LING Yun, LI Jie-Cheng

(College of Mathematics and Information, Fujian Normal University, Fuzhou 350007, China)

**Abstract:** In order to effectively improve the activity classification efficiency in body sensor networks, a maximum likelihood sparse representation algorithm based on K-SVD is proposed in this study. Firstly, all of activity pattern training samples are grouped according their classes to be trained, respectively. The mutual interference among different groups in the process of training can be avoided and sub-dictionaries for every class can be obtained. Then, these sub-dictionaries are used to construct an over-complete dictionary. And the dictionary is able to sparsely represent the testing samples precisely. The sparse representation coefficients are precisely approximated by maximum likelihood sparse model and the recognition result of testing samples are determined by the coefficients. The experimental results show that the proposed algorithm is able to obtain the optimal dictionary and the method based on maximum sparse representation can precisely estimate the representation error of testing activity samples. The accuracy of the proposed algorithm is obviously better than some conventional sparse-representation-based activity recognition algorithms. The proposed algorithm is able to effectively improve the activity pattern classification efficiency in body sensor networks.

**Key words:** body sensor networks; activity recognition; sparse representation; over-completed dictionary; maximum likelihood model

① 基金项目: 福建省科技厅引导性项目(2017Y0028); 福建省省属高校科研专项项目(JK2016006); 福建省教育厅产学研项目(JAT160098); 2017年福建省大学生创新训练项目(201710394053); 教育部人文社会科学研究规划基金(17YJAZH091)

收稿时间: 2017-04-21; 修改时间: 2017-05-09; 采用时间: 2017-05-19

近年来,新兴体域网技术(Body Sensor Networks, BSN)<sup>[1,2]</sup>在人体健康监测、老年人预防跌倒、人体步态康复评价等领域得到广泛关注和应用.其技术实现思路在于将多个采集传感节点(内嵌加速度计或陀螺仪传感器)佩戴于人体肩、手腕、肘、髌、膝、踝等关节处,构建体域网运动模式获取人体运动数据信息,为判别人体运动功能变化提供可靠数据.基于体域网运动数据构建泛化性能优越的动作分类模型是近年来评价人体运动变化研究中的焦点问题,也是国内外众多学者深入探讨的热点问题.早期,相关研究较多关注采用传统机器学习分类算法(诸如人工神经网络技术<sup>[3]</sup>、支持向量机<sup>[4-6]</sup>、决策树<sup>[7-9]</sup>、马尔科夫模型<sup>[10,11]</sup>等)构建体域网动作模式分类模型.文献<sup>[3]</sup>提出一种基于二维加速度数据的三层神经网络动作模式分类模型,所构建分类模型虽简单,但识别率仅为85%;文献<sup>[4]</sup>提出了一种基于无权重特征值的支持向量机体域网动作模式分类模型,虽然识别率可高达97.21%,但所设计分类算法复杂度高、耗时,难以推广实际应用.文献<sup>[11]</sup>提出一种基于半马尔科夫模型(Semi-Markov Conditional Random Fields)的体域网动作模式分类算法,适用范围虽广,但该算法需大量训练样本数据准确获得模型参数,且最高识别率仅为88.47%.此外,早期相关研究较多基于四种动作模式探讨相关动作模式分类模型性能,局限性较强,难以准确判别体域网动作模式连续变化状况.近年,一种新兴稀疏表示分类(Sparse Representation Classification, SRC)算法在体域网动作模式识别研究中受到广泛关注<sup>[12,13]</sup>.其基本思路:将所有训练样本构建一个过完备字典,准确稀疏表示测试样本(即,与测试样本同类为非零系数,非同类为零系数),将体域网动作模式分类问题转化为测试样本稀疏表示系数求解问题,然后基于所求解的稀疏表示系数定义残差确定测试样本类别.文献<sup>[14]</sup>基于多传感节点加速度数据,提出一种基于稀疏表示分类算法的分布式体域网动作模式识别模型,对13种不同动作模式分类,平均识别率可达93.5%.文献<sup>[13]</sup>提出一种基于单个传感节点加速度数据的人体动作模式稀疏表示分类算法,对9种不同动作模式分类,平均识别率可达95.3%.虽然近年相关研究基于稀疏表示分类算法探讨人体动作模式连续变化状况取得较大进展,但仍忽视由大量高维训练样本数据所构建的较大过完备字典对体域网动作模式分类算法性能的影响.更重要的是,近年相关研究大多采用简单平均叠加方法计算

测试样本稀疏表示余差,难以准确逼近不同动作模式在空间的分布状况,也可能影响其分类性能.如何在基于大量训练样本数据优化设计规模较小过完备字典的基础上,准确估计逼近测试样本残差分布,对于减少分类计算复杂度和时间、提高体域网动作模式分类性能至关重要,也是近年相关研究探讨的热点问题.

近年来,一种基于K-SVD学习算法<sup>[15]</sup>优化设计过完备字典在人脸稀疏表示识别、动态手势稀疏表示识别研究中得到广泛应用,其基本思路就是基于优化学习算法,从大量训练样本数据中获得优化过完备字典,即可有效减少样本数据量,又可准确稀疏表示测试样本,确保判别信息不丢失.上述研究成果为我们优化设计过完备字典提供了可借鉴思路.此外,近年一些相关研究提出了基于最大似然估计(Maximum Likelihood Estimation, MLE)模型<sup>[16,17]</sup>准确逼近稀疏表示残差,其基本思想就是将余项的求解由 $l_1$ 或 $l_2$ 范式优化转化为一个似然估计算子,利用最大似然函数,更加准确估算稀疏表示残差值.目前,就相对于由 $l_1$ 或 $l_2$ 范式优化而言,基于最大似然估计模型构建稀疏表示体域网动作模式分类算法,使体域网动作模式训练样本所得最大似然估计函数更具有通用性,能够获得更精确的测试样本表示残差,有效提升体域网动作模式分类性能.

为此,本文提出了一种基于K-SVD的最大似然稀疏表示体域网动作模式分类新算法,其基本思想:首先基于K-SVD优化学习算法,将不同动作模式训练样本按其所属类别分组优化训练,避免各类样本数据训练时相互干扰,得到不同动作模式类别所属的子字典,然后将子字典拼合构成一个完整字典,准确稀疏表示测试样本,最后基于最大似然稀疏模型准确估算稀疏表示系数残差,有效提高动作模式分类性能.本研究采用包含多传感数据的人体动作数据库WARD<sup>[14]</sup>验证本文所提算法有效性.与传统稀疏表示分类算法相比较,本文所提算法能够准确估计测试样本稀疏表示残差,显著提高体域网动作模式识别率.

## 1 基于K-SVD的最大似然稀疏表示体域网动作分类算法

本文所提算法旨在将K-SVD优化学习算法和最大似然估计相结合,优化设计过完备字典,基于较少训练样本数据准确稀疏表示测试动作样本,然后构建测试样本稀疏表示残差最大似然估计模型,判断其类别.

算法框架如图1所示,由优化设计过完备字典的训练阶段和基于最大似然稀疏表示的动作识别阶段组成.训练阶段主要是基于K-SVD分别每个动作类别优化学习获得子字典,然后将所有优化子字典整合一个完

整字典,有效减少冗余样本数据,准确稀疏表示测试样本.识别阶段主要是采用最大似然估计模型估算稀疏表示余差分布密度函数,然后基于余差分布密度函数求解测试样本稀疏表示残差,判别测试样本所属类别.

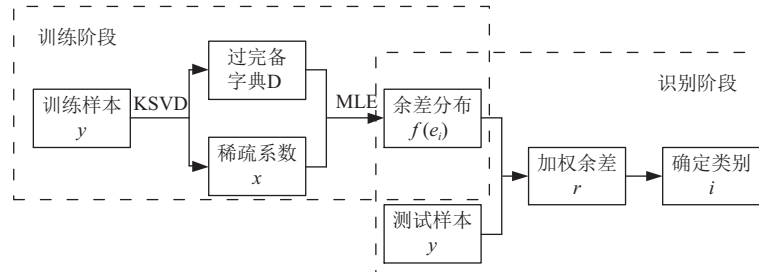


图1 最大似然估计稀疏表示分类算法整体框图

### 1.1 基于K-SVD优化设计过完备字典

K-SVD是近年来提出的一种非常经典的字典训练算法,其基本思想是依据误差最小原则,对误差项进行SVD分解,选择使误差最小的分解项作为更新的字典原子和对应的原子系数,经过不断的迭代从而得到优化的解.本研究为有效降低较大过完备字典对稀疏表示分类算法复杂度的影响,以及避免不同动作类别的相互干扰,提出基于动作类别的K-SVD优化设计过完备字典,减少冗余动作样本信息.假设包含所有动作类别的样本训练集表示为 $Y = [Y_1, Y_2, \dots, Y_k]$ ,其中 $k$ 表示动作模式类别数量.每个动作类别相对应的子字典分别表示为 $D_1, D_2, \dots, D_k$ .K-SVD算法目标方程表示为式(1).

$$\begin{aligned} \langle D_i, X_i \rangle = \arg \min \{ \|Y_i - D_i X\|_2^2 \} \\ \text{s.t. } \forall j, \|x_j\|_0 \leq T_0 \end{aligned} \quad (1)$$

式中, $i = 1, 2, \dots, k$ ,  $T_0$ 是一个常量.对于给定的训练样本集 $Y = \{y_i\}_{i=1}^L$ ,目标字典原子数 $K$ 和收敛条件 $T_0$ ,K-SVD算法步骤如下所示.

#### 算法1. K-SVD算法

1. 初始字典 $D_i^{(0)} \in R^{m \times K}$ ,其每一列均已归一化处理.设置迭代次数 $J=1$ .
2. 采用跟踪算法计算训练样本 $y_i$ 的表示系数 $x_i$ ,并求解下列优化问题:  

$$D_i = \arg \min \{ \|y_i - D_i x_i\|_2^2 \}, \text{s.t. } \|x_i\|_0 \leq T_0, i = 1, 2, \dots, l$$
3. 对字典 $D_i$ 中每一列 $d_k (k = 1, 2, \dots, K)$ ,更新方法如下:
  - (1) 定义一组使用该字典原子的数据样本,  

$$w_k = \{i | 1 \leq i \leq K, x_T^k(i) \neq 0\};$$
  - (2) 计算误差矩阵, $E_k = Y - \sum_{j \neq k} d_j x_T^j$ ;
  - (3) 根据 $E_k$ 选择和 $w_k$ 对应的列,得到 $E_k^R$ ;
  - (4) 对 $E_k^R$ 进行SVD分解: $E_k^R = U \Delta V^T$ .将 $U$ 的列设置为 $d_k$ .并将 $V$ 的第一列与 $\Delta(1, 1)$ 的乘积设置为 $x_T^k$ .
4. 满足收敛条件则停止迭代,否则设置 $J = J + 1$ ,转至步骤2.

基于上述步骤,可得到由每一动作类别的子字典级联而成的一个完整优化过完备字典 $D$ ,既可减少字典规模,又可有效确保动作样本中的判别信息不丢失.

### 1.2 最大似然稀疏表示动作分类模型

基于所得优化过完备字典 $D$ ,可将测试样本 $y$ 稀疏表示为:

$$y = Dx + \sigma \quad (2)$$

式中, $\sigma$ 表示为误差容限,尽可能确保稀疏表示系数 $x = [0, \dots, 0, x_1, x_2, \dots, x_{n_i}, 0, \dots, 0]$ ,非零系数 $x_1, x_2, \dots, x_{n_i}$ 表示与测试样本 $y$ 同类训练样本对应的系数.式(2)稀疏表示系数可通过下列极小化 $l_1$ 范数求解.

$$\hat{x} = \arg \min \|x\|_1 \quad \text{s.t.} \quad \|y - Dx\|_2^2 \leq \sigma \quad (3)$$

式中,约束条件要求余项 $e = y - Dx$ 满足 $\|e\|_2 \leq \sigma$ .为此,基于最大似然估计理论将余项转化为最大似然分布函数,构建最大似然稀疏表示动作分类模型.具体算法描述如下.

将字典 $D$ 改写为 $D = [d_1; d_2; \dots; d_k]$ ,其中行向量 $d_i$ 表示 $D$ 的第 $i$ 行.余项表示为 $e = [e_1; e_2; \dots; e_n]$ ,其中,第 $i$ 行 $e_i = y_i - d_i x, i = 1, 2, \dots, n$ ,且假设 $e_1, e_2, \dots, e_n$ 独立同分布,其概率密度函数记作 $f_\theta(e_i)$ ,其中, $\theta$ 是特征参数.则余项的最大似然函数可表示为: $-\ln L_\theta = \sum_{i=1}^n \rho_\theta(e_i)$ ,其中, $\rho_\theta(e_i) = -\ln f_\theta(e_i)$ .

在稀疏表示模型中,系数 $x$ 具有稀疏性约束.因此,系数 $x$ 的最大似然估计求解可以转化为式(4)所示的最小优化问题.



$$\hat{x} = \arg \min \sum_{i=1}^n \rho_{\theta}(y_i - d_i x) \quad \text{s.t.} \quad \|x\|_1 \leq \sigma \quad (4)$$

一般来说,余差  $e$  不符合高斯分布.但是,可以假设余差  $e$  的概率密度函数  $f_{\theta}(e_i)$  具有高斯分布密度函数所具有的特性:  $f_{\theta}(e_i)$  是对称的,并且当  $|e_i| < |e_j|$  时,  $f_{\theta}(e_i) > f_{\theta}(e_j)$ . 因此,  $\rho_{\theta}(e_i)$  具有以下特性:  $\rho_{\theta}(0)$  是全局最小值; 对称性, 即  $\rho_{\theta}(e_i) = \rho_{\theta}(-e_i)$ ; 单调性, 当  $|e_i| > |e_j|$  时,  $\rho_{\theta}(e_i) < \rho_{\theta}(e_j)$ .

设  $F_{\theta}(e) = \sum_{i=1}^n \rho_{\theta}(e_i)$ , 并对  $F_{\theta}(e)$  在  $e = e_0$  处做一阶泰勒展开, 如式 (5).

$$\widehat{F}_{\theta}(e) = F_{\theta}(e_0) + (e - e_0)^T F'_{\theta}(e_0) + R_1(e) \quad (5)$$

式中,  $R_1(e)$  为高阶余项.  $F'_{\theta}(e_0) = [\rho'_{\theta}(e_{0,1}); \rho'_{\theta}(e_{0,2}); \dots; \rho'_{\theta}(e_{0,n})]$ , 其中,  $e_{0,i} (i = 1, 2, \dots, n)$  表示  $e_0$  中的第  $i$  个元素. 高阶余项  $R_1(e)$  的估计值可记作  $R_1(e) = 0.5(e - e_0)^T W (e - e_0)$ , 其中  $W$  是一个对角矩阵. 因此,  $e$  中的所有元素都是相互独立的.  $F_{\theta}(e)$  在  $e=0$  达到最小值 0, 则当  $e=0$  时,  $\widehat{F}'_{\theta}(e)$  的也达到最小值. 令  $\widehat{F}'_{\theta}(e) = 0$ , 可以计算得到对角矩阵  $W$  对角元素值, 如式 (6).

$$W_{i,i} = \rho'_{\theta}(e_{0,i}) / e_{0,i} \quad (6)$$

根据函数  $\rho_{\theta}(e)$  的特性,  $\rho'_{\theta}(e_i)$  和  $e_i$  的正负符号相同, 所以对角矩阵  $W$  中的所有元素都是非负值. 因此,  $\widehat{F}_{\theta}(e)$  可以改写为  $\widehat{F}_{\theta}(e) = 1/2 \|W^{1/2} e\|_2^2 + b$ ,  $b$  是一个由  $e_0$  决定的常数. 式 (1) 可被改写为式 (7).

$$\hat{x} = \arg \min \|W^{1/2} (y - Dx)\|_2^2 \quad \text{s.t.} \quad \|x\|_1 \leq \sigma \quad (7)$$

比较式 (7) 和式 (3) 可以看出, 最大似然稀疏表示分类方法就是一个加权的稀疏表示模型. 由于权重矩阵  $W$  是一个对角矩阵,  $W_{i,i}$  是针对待测向量中每一个相应原子的权值, 对于差异性较为明显的原子值, 权重较大, 不具有差异性或差异性较小的原子值, 赋予的权重则小一些, 这样的操作对于分类效果的好处是显而易见的. 考虑到上述特性, 选择与其相似的 SVM 算法中 hinge loss 函数<sup>[18]</sup>作为权重函数, 通过迭代优化, 直至收敛, 最终求得稀疏表示系数.

## 2 实验结果与分析

### 2.1 实验数据及其预处理

本研究选用美国加州伯克利大学公开发布的包含多传感数据的人体动作模式数据库 WARD. 该数据库

采集 20 名受试者 (13 名男性, 7 名女性, 年龄在 19~70 岁) 13 种不同动作模式: 站立、坐、躺、向前走、向左转、向右转、上楼、下楼、慢跑、跳、推轮椅、顺时针走、逆时针走. 每名受试者要求佩戴 5 个相同传感节点 (内嵌一个三轴加速度计传感器和一个二轴陀螺仪), 分别置于左手腕、右手腕、左足踝、右足踝、腰部. 采用率设置为 30 Hz. 本研究选用上述前 11 种动作模式数据验证本文所提算法有效性.

为确保所选动作模式数据信息完整性, 本文采用滑动窗口方法截取数据段, 窗口长度设置为 200 点. 选用三个方向的加速度数据和二个方向的陀螺仪数据定义采样数据向量维数为  $m=1000$ . 采用五阶平滑滤波对所选样本数据消噪.

为客观评价本文所提算法的分类性能, 我们采用留一交叉验证法, 即从所有 20 名受试者 (每名受试者每种动作取 5 个样本) 任意选取 19 名受试者数据作为训练样本集, 剩余 1 名受试者作为测试样本. 为确保动作样本训练、测试的可靠性, 上述交叉验证任意重复 75 次, 取最终平均结果作为分类器的识别率.

### 2.2 优化设计过完备字典

由于样本数据维数为  $m=1000$ , 含一些冗余信息, 影响优化过完备字典的获取和分类器的最优性能. 在实验中, 我们采用随机投影方法压缩数据, 降低样本数据冗余信息. 压缩率 (Compressive Proportion, cp) 的定义如式 (8).

$$cp = m' / m \quad (8)$$

式中,  $m'$  表示压缩数据长度. 我们在原始数据维度为  $m=1000$  及优化过完备字典大小取 40 状况下, 选择最优压缩率 cp 值. 本文所提算法基于不同压缩率所获得的识别率和运行时间如表 1 所示.

表 1 本文算法基于不同压缩率的识别率和运行时间

压缩率(cp)	识别率(%)	运行时间(s)
0.05	86.91	4.76
0.1	93.45	5.90
0.2	94.18	6.97
0.5	95.45	10.75
1	95.82	17.99

从表 1 可以看到, 识别率和运行时间均随压缩率的增大而增大, 但压缩率为 0.5 时能够获得与压缩率为 1 时几乎相同的最大识别率, 运行时间却明显减少

(约 7.2 秒). 这些结果表明, 最优压缩率为 0.5. 因为当  $cp=0.5$  时, 压缩数据不仅可包含与原始数据几乎相同的动作模式差异信息, 同时可以有效降低本文所提算法复杂度, 提高动作分类性能.

在选取最优压缩率为 0.5 状况下, 我们进一步评估了基于本文所提算法选取优化过完备字典对动作分类性能的影响. 实验中, 每种动作训练样本数量选取为 95. 图 2 给出了选取不同字典对动作分类性能的影响结果. 从图 2 可以看到, 本文所提算法随选取字典大小变化而变化. 当选取字典大小从 10 增加到 40 时, 动作识别率上升至最大 (约 95%); 其后, 识别率呈下降趋势. 这些结果表明, 字典规模过小, 难以包含动作模式完整差异信息; 字典规模过大, 所选择样本数据必含过多冗余信息, 两者均影响动作分类性能. 但通过优化学习选取规模适当字典, 既可包含动作模式完整差异信息, 又可降低样本数据冗余信息, 有效提高动作模式分类性能.




图 2 基于不同字典大小的识别率变化结果

### 2.3 最大似然稀疏表示动作分类性能

实验中, 我们选取传统的近紧邻算法 (NN)、稀疏表示分类算法 (SRC)、基于 K-SVD 的稀疏表示分类算法 (KSVD+SRC), 作为比较, 进一步客观评价本文所提算法 (KSVD+MLE) 的有效性. 最优字典选取为 40, 其比较结果如图 3 所示.

从图 3 可以看到, 四种动作分类算法动作识别率均随数据维度增长而增长, 比较而言, 本文所提算法 (KSVD+MLE) 可获得最大识别率 (96.36%), 分类性能明显优于其他所选三种分类算法性能, NN 动作分类性能最差. 这些结果表明, 本文所提最大似然稀疏表示模型能够准确估计动作模式稀疏表示系数残差, 有效提高动作模式分类性能.

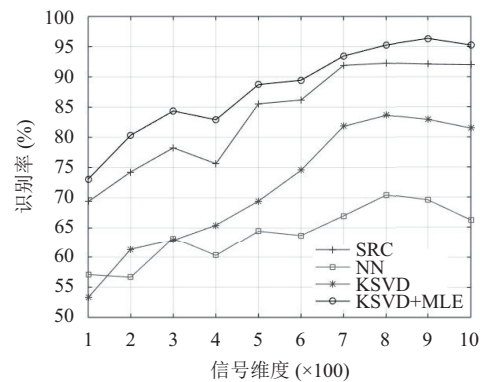


图 3 基于不同动作分类算法的比较结果

此外, 从图 3 中我们观察到, 基于 SRC 的动作分类性能 (识别率为 92.27%) 明显优于基于 KSVD+SRC 的动作分类性能 (83.64%), 原因是 K-SVD 优化字典难以以为 SRC 算法提供精确的稀疏表示系数残差, 影响其分类性能.

此外, 在实验中, 我们基于最优选取字典以及最优压缩率, 验证本文所提算法对所选 11 种动作模式分类性能, 进一步评估本文所提算法对连续动作模式分类有效性. 其分类混淆矩阵如表 2 所示. 从表 2 可以看到, 本文所提算法对 11 种不同动作模式识别率均达到 94% 以上, 平均识别率高达 96% 以上. 特别是, 站立、躺、左转、右转等动作识别率均可高达 98% 以上. 作为对比, SRC 算法对所选 11 种动作模式的分类混淆矩阵如表 3 显示. 可以看出, SRC 算法对坐、上楼、下楼、推轮椅四种动作模式识别率均在 90% 以下, 平均识别率仅为 92%, 比之本文所提算法平均识别率低 4%. 综上, 本文所提算法能够准确估计动作模式稀疏表示系数残差分布, 可有效识别动作模式连续变化.

### 3 结论与展望

本文提出了一种基于 K-SVD 的最大似然稀疏表示动作分类算法. 该算法可有效利用 K-SVD 优化学习算法, 将不同动作模式训练样本按其所属类别分组优化训练, 避免各类样本数据训练时相互干扰, 将不同动作模式类别所属的子字典拼合一个完整字典, 准确稀疏表示测试样本, 使最大似然稀疏模型准确估计稀疏表示系数残差, 有效提高动作模式分类性能, 有助于判别动作模式连续变化.

表2 本文所提算法基于11种动作信号的分类混淆矩阵

动作类别	站立	坐	躺	向前走	左转	右转	上楼	下楼	慢跑	跳	推轮椅	识别率
站立	370	4	0	0	0	0	1	0	0	0	0	0.99
坐	8	361	3	0	2	0	0	0	0	0	1	0.96
躺	0	0	375	0	0	0	0	0	0	0	0	1.00
向前走	4	0	0	357	4	0	5	2	0	1	2	0.95
左转	1	0	0	0	374	0	0	0	0	0	0	0.99
右转	5	0	0	0	0	369	0	0	0	0	1	0.98
上楼	2	0	0	5	2	0	356	2	7	0	1	0.95
下楼	13	1	0	0	0	0	1	352	4	0	4	0.94
慢跑	7	0	0	0	0	0	5	0	361	2	0	0.96
跳	11	0	0	0	0	0	0	2	2	360	0	0.96
推轮椅	2	16	0	0	0	0	0	0	0	0	357	0.95
召回率	0.87	0.945	0.99	0.99	0.98	1.00	0.97	0.98	0.97	0.99	0.98	

表3 SRC算法基于11种动作信号分类混淆矩阵

动作类别	站立	坐	躺	向前走	左转	右转	上楼	下楼	慢跑	跳	推轮椅	识别率
站立	353	13	0	4	1	2	0	0	0	1	1	0.94
坐	20	334	15	0	2	0	0	0	0	0	6	0.89
躺	0	4	371	0	0	0	0	0	0	0	0	0.99
向前走	11	1	0	343	10	8	1	0	0	0	1	0.91
左转	6	0	0	0	369	0	0	0	0	0	0	0.98
右转	3	0	0	0	0	369	0	0	0	0	3	0.98
上楼	5	0	0	5	6	3	333	2	8	0	13	0.88
下楼	11	4	0	3	1	0	17	320	9	0	10	0.85
慢跑	13	0	0	0	0	0	10	1	347	4	0	0.96
跳	15	1	0	0	0	2	1	1	6	349	0	0.93
推轮椅	7	37	0	3	0	3	0	2	0	0	323	0.86
召回率	0.80	0.85	0.99	0.96	0.95	0.95	0.92	0.98	0.94	0.99	0.90	

## 参考文献

- Movassaghi S, Abolhasan M, Lipman J, *et al.* Wireless body area networks: A survey. *IEEE Communications Surveys & Tutorials*, 2014, 16(3): 1658–1686.
- Rawat P, Singh KD, Chaouchi H, *et al.* Wireless sensor networks: A survey on recent developments and potential synergies. *The Journal of Supercomputing*, 2014, 68(1): 1–48. [doi: 10.1007/s11227-013-1021-9]
- Randell C, Muller H. Context awareness by analysing accelerometer data. *The Fourth International Symposium on Wearable Computers*. Atlanta, GA, USA. 2000. 175–176.
- He ZY, Liu ZB, Jin LW, *et al.* Weightlessness feature-A novel feature for single tri-axial accelerometer based activity recognition. *19th International Conference on Pattern Recognition*. Tampa, FL, USA. 2008. 1–4.
- He ZY, Jin LW. Activity recognition from acceleration data based on discrete cosine transform and SVM. *Proceedings of the 2009 IEEE International Conference on Systems, Man and Cybernetics*. San Antonio, TX, USA. 2009. 5041–5044.
- He ZY, Jin LW. Activity recognition from acceleration data using AR model representation and SVM. *Proceedings of the Seventh International Conference on Machine Learning and Cybernetics*. Kunming, China. 2008. 2245–2250.
- Jatoba LC, Grossmann U, Kunze C, *et al.* Context-Aware mobile health monitoring: Evaluation of different pattern recognition methods for classification of physical activity. *30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Vancouver, BC, Canada. 2008. 5250–5253.
- Bao L, Intille SS. Activity recognition from user-annotated acceleration data. *International Conference on Pervasive Computing*. Linz and Vienna, Austria. 2004. 1–17.
- Ernes M, Parkka J, Cluitmans L. Advancing from offline to online activity recognition with wearable sensors. *30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Vancouver, BC, Canada. 2008. 4451–4454.
- Zhu C, Sheng WH. Human daily activity recognition in

- robot-assisted living using multi-sensor fusion. 2009 IEEE International Conference on Robotics and Automation. Kobe, Japan. 2009. 2154–2159.
- 11 Vinh LT, Lee S, Le HX, *et al.* Semi-Markov conditional random fields for accelerometer-based activity recognition. *Applied Intelligence*, 2011, 35(2): 226–241. [doi: [10.1007/s10489-010-0216-5](https://doi.org/10.1007/s10489-010-0216-5)]
- 12 Wright J, Yang AY, Ganesh A, *et al.* Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 210–227. [doi: [10.1109/TPAMI.2008.79](https://doi.org/10.1109/TPAMI.2008.79)]
- 13 Zhang M, Sawchuk AA. Human daily activity recognition with sparse representation using wearable sensors. *IEEE Journal of Biomedical and Health Informatics*, 2013, 17(3): 553–560. [doi: [10.1109/JBHI.2013.2253613](https://doi.org/10.1109/JBHI.2013.2253613)]
- 14 Yang AY, Jafari R, Sastry SS, *et al.* Distributed recognition of human actions using wearable motion sensor networks. *Journal of Ambient Intelligence and Smart Environments*, 2009, 1(2): 103–115.
- 15 Aharon M, Elad M, Bruckstein A. rmK-SVD: An algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311–4322. [doi: [10.1109/TSP.2006.881199](https://doi.org/10.1109/TSP.2006.881199)]
- 16 Yang M, Zhang L, Yang J, *et al.* Robust sparse coding for face recognition. 2011 IEEE Conference on Computer Vision and Pattern Recognition. Providence, RI, USA. 2011. 625–632.
- 17 胡正平, 宋淑芬. 基于类别相关近邻子空间的最大似然稀疏表示鲁棒图像识别算法. *自动化学报*, 2012, 38(9): 1420–1427.
- 18 Zhang J, Jin R, Yang YM, *et al.* Modified logistic regression: An approximation to SVM and its applications in large-scale text categorization. *Proceedings of the Twentieth International Conference on Machine Learning*. Washington DC, USA. 2003. 888–895.