

## 体域网中一种基于压缩感知的人体动作识别方法

肖玲<sup>\*①②</sup> 李仁发<sup>①</sup> 罗娟<sup>①②</sup>

<sup>①</sup>(湖南大学嵌入式系统与网络实验室 长沙 410082)

<sup>②</sup>(湖南大学信息科学与工程学院 长沙 410082)

**摘要:** 能量有效性是无线体域网在面向长时间健康监测应用的首要挑战。该文引入压缩感知和稀疏表示理论同时解决人体活动监测中的动作识别和数据压缩问题,探索在达到一定动作识别率的同时降低传感器节点的能耗。该文提出的压缩分类动作识别方法首先在传感器节点利用随机投影对传感数据进行压缩,传到中心节点后再利用稀疏表示对压缩采样数据进行分类与识别,可减少传感器节点处理、传输原始数据所带来的能耗。在公开的可穿戴式传感器动作识别数据库 WARD(Wearable Action Recognition Database)验证算法性能,实验结果表明该动作识别方法能有效地对随机投影后的低维采样数据进行识别,具有与传统识别方法相比拟的动作识别准确率。

**关键词:** 无线体域网; 压缩感知; 动作识别; 微惯性传感器; 能量有效

中图分类号: TP393; TP391

文献标识码: A

文章编号: 1009-5896(2013)01-0119-07

DOI: 10.3724/SP.J.1146.2012.00936

## Recognition of Human Activity Based on Compressed Sensing in Body Sensor Networks

Xiao Ling<sup>①②</sup> Li Ren-fa<sup>①</sup> Luo Juan<sup>①②</sup>

<sup>①</sup>(Laboratory of Embedded Systems and Networks, Hunan University, Changsha 410082, China)

<sup>②</sup>(School of Information Science and Engineering, Hunan University, Changsha 410082, China)

**Abstract:** Energy efficiency is a primary challenge in wireless body sensor networks for the long-term physical movement monitoring. In order to reduce the energy consumption while maintaining the sufficient classification accuracy of the human activity, a compressed classification approach is explored combining classification with data compressing based on sparse representation and compressed sensing. The proposed approach firstly compresses the sensing data by random projection on the sensor nodes, and then recognizes activities on compressed samples after transmitting to the central node by sparse representation, which can reduce the energy transmission of original data. The performance of the method is evaluated on the opened Wearable Action Recognition Database (WARD). Experimental results are validated that the compressed classifier achieves comparable recognition accuracy on the compressed sensing data.

**Key words:** Wireless Body Sensor Networks (WBSN); Compressive sensing; Activity recognition; Inertial sensors; Energy efficiency

### 1 引言

随着微机电系统、无线通信和传感器网络的发展,集数据采集、处理和通信为一体的无线传感器节点越来越普及,由放置在人身体不同部位的多个传感器节点构成的无线体域网(Wireless Body Sensor Networks, WBSN)<sup>[1]</sup>在老年人日常活动监测、慢性病人监护、康复辅助训练方面得到广泛应用。基于惯性传感器的人体动作识别成为新的研究热点。相比基于视觉的人体运动识别,它具有设备

简单、可长时间监控和易于集成等优点。但要想实现长时间的监测,传感器节点的能量消耗是制约其实际应用的关键原因。本文用压缩感知和稀疏表示理论同时解决解决人体动作识别和传感数据压缩问题,探索在达到一定动作识别率的同时降低传感器节点的能耗。

基于微惯性传感器的动作识别属于模式识别领域的一个新兴分支,其本质是通过多个惯性传感器获取身体活动时产生的运动信号,然后对数据进行预处理、特征提取与选择,最后根据提取的特征对动作状态进行分类和识别。目前大部分的研究工作都是围绕着提高动作识别率而展开,采用了各种模

2012-07-19 收到, 2012-11-02 改回

国家自然科学基金(61173036, 61173012)资助课题

\*通信作者: 肖玲 xiaoling@hun.edu.cn

式识别方法,如决策树(decision tree)<sup>[2]</sup>、人工神经网络(Artificial Neural Network, ANN)<sup>[3]</sup>、支持向量机(Support Vector Machines, SVM)<sup>[4]</sup>和多级分层的方法<sup>[5]</sup>等。另一方面,也有学者围绕着体域网中的数据压缩问题进行研究<sup>[6,7]</sup>。但是前面的研究针对动作识别和数据压缩是独立进行的,没有把两者关联起来。传统的识别方法是先直接把原始数据传送到中心节点后再进行识别,这样不适于带宽和能量有限的体域网。针对这个问题,一些研究者考虑把一些简单的任务放到传感器节点上进行,如在传感器节点上进行特征提取<sup>[8]</sup>、局部分类<sup>[9,10]</sup>等,以减少节点传送的数据量。

近年来新出现的压缩感知理论(compressed sensing)<sup>[11]</sup>广泛应用于信号处理领域。基于信号稀疏性的压缩感知理论成功实现了信号的同时采样与压缩,通过采集少量的信号投影值就可重建原始信号。但是有许多信号处理的最终目的并不是重构信号,而是为了得到有关目标的信息,比如信号分类、目标检测等,可以直接利用少量的测量值来进行像信号分类等各种信号处理任务<sup>[12]</sup>。文献[13]提出了压缩分类(compressed classification)的概念,即直接对压缩样本进行分类。

由于动作信号具有稀疏性,本文引入压缩感知和稀疏表示理论同时解决人体活动监测中的数据压缩和动作识别问题,提出一种压缩分类动作识别方法,首先利用压缩感知的随机投影对传感器数据进行压缩,然后利用稀疏表示对压缩采样数据进行分类与识别。相比于经典的数据降维方法,如主成分分析(Principle Component Analysis, PCA)、线性判别分析(Linear Discriminant Analysis, LDA)等,随机投影具有计算复杂性低的优点而适合在资源有限的传感器节点上进行<sup>[14]</sup>。随机投影的另一优点是一种独立于数据的降维方法,可以随机选取测量方案而无需获取任何数据的先验知识。压缩分类方法一方面可以减少识别系统的计算代价。另一个更重要的方面是考虑到传感器节点绝大部分能量都消耗在无线通信模块,在传感器节点上进行随机投影,就可以减少传感器节点要传送的数据量,达到节能的目的。如果随着技术发展,有类似于单像素压缩感知相机的新型传感器,最终可由传感器直接实现压缩采样,则能有效地降低处理、存储、传输数据所带来的功耗。

压缩分类器面临的两大挑战是:(1)压缩分类方法在处理原始信号时应具有与传统分类方法相比拟的分类与识别精度;(2)压缩分类方法应能够有效地对随机投影后的压缩采样信号进行分类与识别。本

文的主要目的是考察提出的压缩分类方法对动作识别的有效性。

## 2 动作识别问题描述与稀疏表示分类模型

对于人体动作识别,像步行、跑步和跳跃等不同动作行为,由分布在身体各关节的惯性传感器测量的观测向量所对应形成的运动轨迹近似分布在不同的几何子空间中,每个子空间代表一个动作类别,因此动作识别问题可以转化为稀疏表示分类模型,可将 Wright 等人<sup>[15]</sup>提出的基于稀疏表示分类(Sparse Representation Classification, SRC)的人脸识别方法运用到动作识别中。

假设总共有由  $L$  个微惯性传感器测试  $K$  种不同的动作。每个传感器包含一个3轴加速度计  $(x, y, z)$  和一个2轴陀螺仪  $(\theta, \varphi)$ , 节点  $j$  在  $t$  时刻的采样值构成一个1维动作观测向量, 记为

$$\mathbf{a}^j(t) = [x^j(t), y^j(t), z^j(t), \theta^j(t), \varphi^j(t)] \in \mathbb{R}^5 \quad (1)$$

相应的第  $j$  个传感器节点在动作持续一段时长内的  $h$  次采样值构成了一个1维动作向量, 记为

$$\mathbf{s}^j = [a^j(1), a^j(2), \dots, a^j(h)] \in \mathbb{R}^{5h} \quad (2)$$

那么由所有  $L$  个传感器节点的采样值构成的一个1维动作向量, 记为

$$\mathbf{v} = [s^1, s^2, \dots, s^L]^T \in \mathbb{R}^{5Lh} \quad (3)$$

由第  $i$  类动作对应的训练集中的所有1维运动向量构成了字典集

$$\mathbf{V}_i = [v_{i,1}, v_{i,2}, \dots, v_{i,n_i}] \in \mathbb{R}^{5Lh \times n_i} \quad (4)$$

其中  $n_i$  表示第  $i$  类动作的训练集中动作向量的数目,  $\mathbf{v}_{i,j}$  表示第  $i$  类动作第  $j$  次的动作向量。

若该待识别的动作向量  $\mathbf{v}_{k,\text{test}}$  属于第  $k$  类动作, 则应该近似有式(5)的线性表示:

$$\mathbf{v}_{k,\text{test}} = \alpha_{k,1} \mathbf{v}_{k,1} + \alpha_{k,2} \mathbf{v}_{k,2} + \dots + \alpha_{k,n_k} \mathbf{v}_{k,n_k} \quad (5)$$

其中向量  $\mathbf{a}_{i,j} \in \mathbb{R}$ ,  $j = 1, 2, \dots, n_i$ 。

将整个训练集中所有  $K$  种动作向量的所有样本串接起来, 组成字典矩阵  $\mathbf{V}$ , 其形式如式(6):

$$\mathbf{V} = [\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_K] = [v_{1,1}, v_{1,2}, \dots, v_{K,m_K}]^T \in \mathbb{R}^{m \times n} \quad (6)$$

其中  $m = 5hL$ ,  $n = n_1 + n_2 + \dots + n_K$ 。

当给定一个待识别的动作向量  $\mathbf{v}_{k,\text{test}}$  时, 需要判断它所属的动作类别。利用稀疏表示分类方法将动作分类问题转化为求解多元线性回归模型。因为实际测量过程中会不可避免地存在一些测量误差, 可用式(7)表示:

$$\mathbf{v}_{k,\text{test}} = \mathbf{V}\boldsymbol{\alpha} + \boldsymbol{\varepsilon} \in \mathbb{R}^m \quad (7)$$

其中  $\boldsymbol{\varepsilon} \in \mathbb{R}^m$  为观测噪声。

由压缩感知理论可得, 只要问题的解足够稀疏, 可采用二次约束下极小化  $l_1$  范数的方法进行求解。

$$\hat{\alpha} = \arg \min \|\alpha\|_1, \quad \text{s.t.} \quad \|\mathbf{v}_{k,\text{test}} - \mathbf{V}\alpha\|_2 \leq \varepsilon \quad (8)$$

在理想情况下, 如果待识别动作向量  $\mathbf{v}_{k,\text{test}}$  是属于第  $k$  类, 则解向量  $\alpha$  中只有与第  $k$  类训练数据对应的元素不为零, 其他元素都为 0。实际情况中由于噪声的存在, 非零元素也可能会发生在其他位置。则计算该待测动作向量与每一类中所有训练动作向量的线性加权的差值  $r_i(\mathbf{v}_{k,\text{test}})$ , 如式(9):

$$r_i(\mathbf{v}_{k,\text{test}}) = \|\mathbf{v}_{k,\text{test}} - \mathbf{V}\delta_i(\hat{\alpha})\|_2, \quad i = 1, 2, \dots, k \quad (9)$$

式中  $\delta_i(\hat{\alpha})$  表示提取稀疏系数  $\hat{\alpha}$  中与第  $i$  类的所有训练动作向量对应的系数, 而其余的系数均为 0。选择差值最小的  $r_i(\mathbf{v}_{k,\text{test}})$  所属的类别为最终的识别结果。

### 3 压缩分类动作识别方法

由于动作信号具有稀疏性, 本文提出的压缩分类动作识别方法, 首先利用压缩感知的随机投影对传感器数据进行压缩, 然后利用稀疏表示对压缩采样数据进行分类与识别。

#### 3.1 随机投影

随机投影是近年来出现的一种有效的数据降维方法, 它具有计算复杂度低和距离保持特性的优点。

在每个传感器节点, 将  $m$  维的高维信号通过随机投影矩阵  $\mathbf{A}$  投影到一个  $d$  维的低维子空间 ( $d \ll m$ ), 表示为

$$\mathbf{X}_{d \times n}^{RP} = \mathbf{A}_{d \times m} \mathbf{X}_{m \times n} \quad (10)$$

其中  $\mathbf{X}_{d \times n}^{RP}$  表示投影后的数据,  $\mathbf{A}_{d \times m}$  为投影矩阵。

投影矩阵  $\mathbf{A}$  的选择成为了关键。通常不太可能找到确定的投影矩阵满足约束等距性 (Restricted Isometry Property, RIP) 条件, 但独立同分布的随机矩阵被证明能以较高概率满足 RIP 条件, 如高斯随机矩阵和伯努利随机矩阵<sup>[16]</sup>。本文实验中在测试动作识别算法对随机投影后的数据的识别性能时也选用这两种矩阵。

一个  $d \times m$  的高斯随机投影矩阵指满足矩阵中的元素  $\phi_{i,j}$  是独立的随机变量且都服从式(11)分布:

$$\phi_{i,j} \sim N(0, 1/d) \quad (11)$$

一个  $d \times m$  的伯努利随机投影矩阵指满足矩阵中的元素  $\phi_{i,j}$  是独立的随机变量且都服从式(12)分布:

$$P(\phi_{i,j} = \pm 1/\sqrt{d}) = 1/2 \quad (12)$$

相对于传统的数据降维方法 PCA 而言, 随机投影的计算代价只跟 PCA 中矩阵相乘所需的计算代价相同, 而省去了 PCA 中计算协方差矩阵和进行特征分析所需的计算代价。低的计算代价使随机投影适合在资源有限的传感器节点上实现。

#### 3.2 随机投影下的稀疏表示分类动作识别方法

当传感器节点  $j$  的随机投影矩阵  $\mathbf{A}^j$  选好后, 则在传感器节点  $j$  对运动向量  $\mathbf{v}_{k,\text{test}}^j$  进行随机投影:

$$\tilde{\mathbf{v}}_{k,\text{test}}^j = \mathbf{A}^j \mathbf{v}_{k,\text{test}}^j \in \mathbb{R}^{d^j} \quad (13)$$

每个传感器节点把经过随机投影后的向量  $\tilde{\mathbf{v}}_{k,\text{test}}^j$  传到中心节点, 由中心节点收集到的经  $L$  个传感器节点投影后的待测运动向量  $\tilde{\mathbf{v}}_{k,\text{test}}$  表示为

$$\tilde{\mathbf{v}}_{k,\text{test}} = [\tilde{v}_{k,\text{test}}^{1T}, \dots, \tilde{v}_{k,\text{test}}^{LT}]^T \in \mathbb{R}^d \quad (14)$$

满足下面的线性关系:

$$\tilde{\mathbf{v}}_{k,\text{test}} = \begin{bmatrix} A^1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & A^L \end{bmatrix} \begin{bmatrix} v_{k,\text{test}}^1 \\ \vdots \\ v_{k,\text{test}}^L \end{bmatrix} = \mathbf{A}\mathbf{V}\beta + \eta \quad (15)$$

其中  $\mathbf{A} \in \mathbb{R}^{d \times m}$  为由  $L$  个  $\mathbf{A}^j$  组成的新投影矩阵。投影后的特征维数  $d$  远远小于训练样本的个数  $n$ , 线性方程是欠定的, 有无穷多组解。但只要问题的解  $\beta$  足够稀疏, 在矩阵  $\mathbf{A}\mathbf{V}$  满足 RIP 条件下, 由压缩感知理论可知式(15)可通过最小化  $l_1$  范数下的优化问题求解。

$$\hat{\beta} = \arg \min \|\beta\|_1, \quad \text{s.t.} \quad \|\mathbf{A}\mathbf{v}_{k,\text{test}} - \mathbf{A}\mathbf{V}\hat{\beta}\|_2 \leq \eta \quad (16)$$

解出  $\beta$  后, 后面的步骤同第 2 节的 SRC 算法一样, 计算差值并选择差值最小  $r_i(\mathbf{v}_{k,\text{test}})$  的所属的类别为最终的识别结果。随机投影下的稀疏表示分类动作识别方法 (Sparse Representation Classification with Random Projection, SRC-RP), 具体实现过程如下:

步骤 1 初始化: 训练样本集  $\mathbf{V} = [v_{1,1}, v_{1,2}, \dots, v_{k,m_k}]^T$ , 测试样本  $\mathbf{v}_{k,\text{test}}$ , 每个传感器节点的随机投影矩阵  $\mathbf{A}^j$ , 误差容忍参数  $\eta$ 。

步骤 2 在每个传感器节点利用随机投影矩阵和测试样本计算随机投影值, 发送到中心节点。

步骤 3 在与中心节点相连的后台利用各个节点的随机投影矩阵和训练样本集构建过完备字典, 字典的各列必须经过了归一化处理。

步骤 4 通过求解最小化  $l_1$  范数下的优化问题得到稀疏系数。

步骤 5 计算残差, 选择差值最小的为最终的识别结果。

#### 3.3 SRC-RP 方法对随机投影数据的识别有效性分析

Wright 等人<sup>[15]</sup> 首先通过实验验证了他们提出的稀疏表示分类方法在对人脸图像进行随机低维投影的情况下也能获得了较高的识别率, 但未给出理论证明。

SRC-RP 算法能对经过随机投影后的压缩样本

进行分类。求解最小化  $l_1$  范数下的优化问题, 即式(16)是关键。首先分析能转化为式(16)求解的前提是矩阵  $\mathbf{AV}$  满足 RIP 条件。

在压缩感知理论中, 为了能从  $m$  维测量值中重构出  $n$  维信号, 即  $\mathbf{s} = \mathbf{\Psi}\mathbf{x}$ , 文献[16]证明了矩阵  $\mathbf{\Psi} \in \mathbb{R}^{m \times n}$  应满足 RIP 条件, 即: 存在常数  $\delta_A \in (0, 1)$ , 有式(17)成立

$$(1 - \delta_A) \|\mathbf{x}\|_2^2 \leq \|\mathbf{\Psi}_A \mathbf{x}\|_2^2 \leq (1 + \delta_A) \|\mathbf{x}\|_2^2 \quad (17)$$

其中  $A \subset \{1, \dots, n\}$ ,  $\mathbf{\Psi}_A$  为  $\mathbf{\Psi}$  中由索引  $A$  所指示的相关列构成的子矩阵。

文献[17]扩展了压缩感知的概念, 把信号从正交基下稀疏扩展到在冗余字典下稀疏, 给出了什么样条件下的测量矩阵满足 RIP 条件, 并给出了证明。当信号  $\mathbf{y}$  在冗余字典下稀疏时, 即有  $\mathbf{s} = \mathbf{A}\mathbf{y} = \mathbf{A}\mathbf{\Phi}\mathbf{x} = \mathbf{\Psi}\mathbf{x}$ , 其中冗余字典  $\mathbf{\Phi}$  为  $m \times n$ , 随机矩阵  $\mathbf{A}$  为  $d \times n$ , 当所取的随机矩阵  $\mathbf{A}$  为高斯随机投影矩阵或伯努利随机投影矩阵时, 矩阵  $\mathbf{\Psi} = \mathbf{A}\mathbf{\Phi}$  能以较高概率满足 RIP 条件, 即: 对  $\delta \in (0, 1)$ , 设  $v := \delta_A + \delta + \delta_A \delta$ , 则有大于  $1 - 2(1 + 12/\delta)^S e^{-(c/9)\delta^2 n}$  的概率 ( $c$  为一个与所选随机投影矩阵有关的常量) 满足式(18):

$$(1 - v) \|\mathbf{x}\|_2^2 \leq \|\mathbf{A}\mathbf{\Phi}\mathbf{x}\|_2^2 \leq (1 + v) \|\mathbf{x}\|_2^2 \quad (18)$$

同理, 当 SRC-RP 算法中待测的动作向量  $\mathbf{v}_{k, \text{test}}$  为冗余字典  $\mathbf{V}$  的稀疏表示时 ( $\boldsymbol{\alpha}$  的系数中只有与第  $k$  类对应的不为 0, 其余的都为 0, 可见  $\boldsymbol{\alpha}$  是一个具有  $1/K$  稀疏度的稀疏向量), 且所取的随机投影矩阵为高斯随机投影矩阵或伯努利随机投影矩阵, 矩阵  $\mathbf{AV}$  能以较高概率满足 RIP 条件。

SRC-RP 算法把对经过随机投影后的压缩样本进行分类与对原始采样样本进行分类比较, 发现关键是最小化  $l_1$  范数下的优化问题求解式不同。

比较最小化  $l_1$  范数求解式(16)与式(8), 目标函数在投影前后没有改变, 约束条件变了。只要证明在两式中的约束条件是近似的, 则两个优化函数是近似相同的, 它们的解也近似相同, 即  $\beta \approx \alpha$ 。两式中的约束条件近似相同的证明如下:

对于 RIP 条件式(17)中, 如果  $\mathbf{\Psi}$  取随机投影矩阵  $\mathbf{A}$ , 去掉上下限约束, 则近似有  $\|\mathbf{A}\mathbf{x}\|_2 \approx \|\mathbf{x}\|_2$ , 则有

$$\begin{aligned} \|\mathbf{A}\mathbf{v}_{k, \text{test}} - \mathbf{AV}\beta\|_2 &\leq \eta = \|\mathbf{A}(\mathbf{v}_{k, \text{test}} - \mathbf{V}\beta)\|_2 \leq \eta \\ &\approx \|(\mathbf{v}_{k, \text{test}} - \mathbf{V}\beta)\|_2 \leq \eta \end{aligned} \quad (19)$$

因此, SRC-RP 对随机投影后的压缩采样数据的识别率可达到与对原始数据的识别率相近似的结果。接下来由实验进一步进行验证。

## 4 实验结果与分析

### 4.1 WORD 数据集

本文采用美国加州伯克利大学的 Yang 提供的可穿戴式传感器的动作识别数据库 (Wearable Action Recognition Database, WARD)<sup>[10]</sup>。共采用 5 个 Tmote 节点, 分别捆绑在腰部、2 个手腕和 2 个脚踝处。每个节点嵌有一个 3 轴加速度传感器和一个 2 轴陀螺仪, 节点的采样率为 20 Hz。有 20 个不同年龄、身高、体重的采集者 (13 位男性, 7 位女性)。13 种动作分别是: 1. 站、2. 坐、3. 躺、4. 往前走、5. 逆时针走、6. 顺时针走、7. 向左转、8. 向右转、9. 上楼、10. 下楼、11. 慢跑、12. 跳、13. 推轮椅。每个采集者每种动作做 5 次。数据库共收集了 20 个采集者在自然状态下的 1300 个动作样本。

### 4.2 实验结果

实验选取滑动窗口长度为 2 s, 即在采样频率为 20 Hz 下的 40 个采样点。从每个样本中随机选取一段长为 40 个采样点的数据构成训练集, 每个采样点包含 3 轴加速度传感器的 3 个值和 2 轴陀螺仪的 2 个值, 共 5 个值。由 5 个传感器节点构成的运动向量维数  $m=1000$ 。在实验前首先对数据进行五阶平滑滤波来滤除干扰噪声。实验中 SRC-RP 算法的求解利用了 MATLAB 求解优化问题的工具包<sup>[18]</sup>。

**4.2.1 动作信号的稀疏性验证** 压缩感知的一个重要的先验知识就是信号应具有稀疏性。为验证惯性传感器采集的运动信号的可压缩性, 实验中对运动信号进行离散余弦变换 DCT (Discrete Cosine Transform), 求得其系数。选取了放置在膝盖上的加速度传感器在采集走路和上楼这两个动作时的 X 轴信号进行验证, 结果如图 1 所示。采集的动作加速度信号通过 DCT 变换后, 大部分的 DCT 系数都集中在低频部分, 说明利用加速度传感器采集的动作信号在某组变换基下是稀疏的, 满足压缩感知的前提条件。

**4.2.2 SRC-RP 方法的测试结果** 测试 SRC-RP 压缩分类方法的识别性能, 并比较它与最近邻居 NN 分类、最近子空间 NS 分类这两类传统分类方法的性能。测试时采用留一验证 (leave-one-subject-out validation) 法, 即从 20 个采集者的动作数据中选出 19 个人的数据做训练集 ( $n=1235$ ), 然后用剩下 1 个人的数据做测试。这种留一法的验证过程重复 19 遍, 得到相对应的个体无关 (subject-independent) 的动作识别准确率。实验中选用两种类型的随机投影矩阵: 高斯随机投影矩阵和伯努利随机投影矩阵, 每种类型的随机矩阵都分别产生 5 次随机矩阵进行测试。

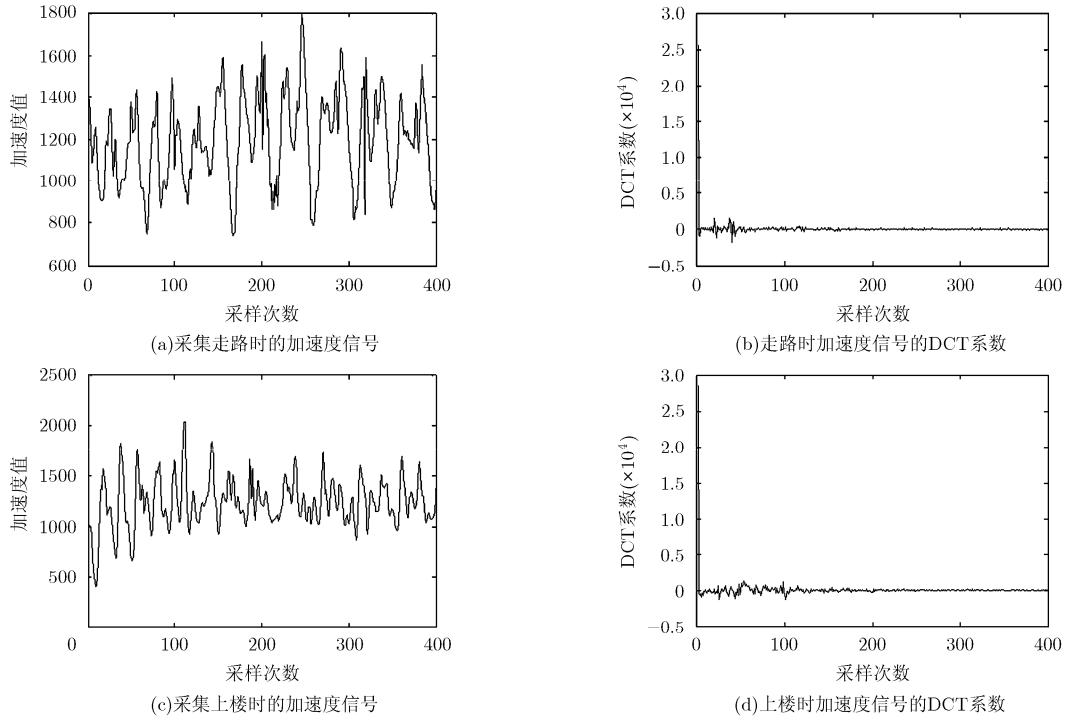


图 1 动作信号的稀疏性验证

3 种分类器在不同压缩比下的平均识别准确率如图 2 所示。压缩比为投影后的动作向量维数与原始动作向量维数的比值( $d/m$ )。当压缩比为 1 时,即为没经过压缩的原始采样数据。SRC-RP 的识别率为 89%, NS 和 NN 的识别率分别为 83%和 81%,结果表明 SRC-RP 在处理原始信号时的识别准确率要高于 NS 和 NN,分析其原因是 SRC-RP 分类时利用了所有类的所有样本,而 NS 只利用了同一类的所有样本,NN 则只利用一个样本。结果说明压缩分类方法在处理原始信号时具有与传统分类方法相比拟的分类与识别精度。在相同压缩比的情况下, SRC-RP 的识别准确率也要高于 NS 和 NN。SRC-RP 分类器随着压缩比的增大,其识别准确率平滑增长,在达到一定的投影维数后, SRC-RP 识别率趋于稳定。而 NS 分类器则随着压缩比的增大,其识别准确率的增长变化相差很大。NS 在压缩比很低的时候,即数据维数很低时,识别率也非常低。SRC-RP 分类器对随机投影后的低维动作测量向量的识别性能要优于 NS 和 NN 分类器。实验中选取了两种不同的随机矩阵下来测试其识别率,结果显示在其它条件相同时,两种随机投影矩阵的识别率差别很小。

表 1 给出了 3 种压缩分类器(SRC-RP, NS, NN)的动作识别率在两种不同随机投影矩阵(高斯随机矩阵和伯努力随机矩阵)下的均方差。结果显示,识别率的均方差跟数据的压缩比,即投影后的数据维




图 2 3 种分类器在不同压缩比和随机投影矩阵下的动作识别率

表 1 动作识别率在不同压缩比和不同随机投影矩阵下的均方差

不同压缩比+ 随机投影矩阵	SRC-RP	NS	NN	
0.1	高斯随机投影矩阵	1.34	1.76	1.53
	伯努力随机投影矩阵	1.36	1.71	1.56
0.3	高斯随机投影矩阵	1.22	1.45	1.31
	伯努力随机投影矩阵	1.25	1.49	1.35
0.5	高斯随机投影矩阵	0.48	0.52	0.48
	伯努力随机投影矩阵	0.52	0.56	0.51

数有关。当投影后的数据维数较低时,均方差较大。均方差随着投影后的数据维数增大到减少,并趋于稳定。

表 2 列出了 SRC-RP 分类器在压缩比为 0.5 时的混淆矩阵,显示每个动作正确识别和误识别动作

表 2 13 种动作类别的混淆矩阵

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	83	10	0	0	0	0	3	1	0	0	0	0	3
2	11	81	3	0	0	0	0	0	0	1	0	0	4
3	0	1	99	0	0	0	0	0	0	0	0	0	0
4	5	1	0	79	4	4	1	0	1	1	1	0	3
5	1	3	0	1	90	0	2	0	2	0	0	1	0
6	5	4	0	2	0	81	2	0	0	0	2	0	4
7	3	1	0	2	0	0	91	0	0	0	0	0	3
8	3	1	0	3	3	0	0	84	0	0	1	0	5
9	0	0	0	1	0	0	0	0	82	3	7	0	7
10	1	0	0	0	6	2	0	0	4	79	2	0	6
11	0	0	0	0	0	0	0	0	0	0	100	0	0
12	0	0	0	0	0	0	0	0	0	1	1	98	0
13	1	2	0	0	0	0	0	0	0	2	1	4	90

的百分比数。由混淆矩阵可见,对于动作 1(站)和动作 2(坐)、动作 9(上楼)和动作 10(下楼)这样的动作容易产生误判,主要是因为 WARD 数据库中用于判别下半身动作的 2 个传感器节点放在脚踝处,导致这些动作之间的区分度不大。

## 5 结束语

本文运用压缩感知和稀疏表示理论同时解决体域网中数据压缩和人体动作识别问题,探索在达到一定动作识别率的同时降低传感器节点的能耗,提出了 SRC-RP 动作识别算法,并在真实的动作识别数据集上验证了算法的有效性。实验结果表明 SRC-RP 算法在处理原始信号时具有与传统分类方法相比拟的分类与识别精度;SRC-RP 算法能够有效地对随机投影后的压缩采样信号进行识别。

目前是通过仿真实验验证了随机投影方法在传感器节点实现下,识别算法的有效性。下一步将尝试直接在传感器节点上真实实现随机投影过程。另外利用由多个微惯性传感器构建的体域网采集人体运动加速度信息,建立自己的动作识别数据集,考察多个惯性传感器节点放置在身体的位置,以尽可能增大采集到的原始动作向量的区分度,提高 SRC-RP 方法的识别性能。考察 SRC-RP 算法对随机投影后的数据识别的鲁棒性,随机投影后的数据维数的最佳取值、SRC-RP 的性能与数据压缩比之间的关系还有待进一步的研究,可利用压缩感知的相关理论和最新研究成果来推导并验证。

## 参 考 文 献

- [1] 宫继兵,王睿,崔莉. 体域网 BSN 的研究进展及面临的挑战[J]. 计算机研究与发展, 2010, 47(5): 737-753.
- [2] Gong Ji-bing, Wang Rui, and Cui Li. Research advances and challenges of body sensor network[J]. *Journal of Computer Research and Development*, 2010, 47(5): 737-753.
- [3] Ghasemzadeh H and Jafari R. Physical movement monitoring using body sensor networks: a phonological approach to construct spatial decision tress[J]. *IEEE Transactions on Industrial Informatics*, 2011, 7(1): 66-77.
- [4] Wang Z L, Jiang M, Hu Y H, et al.. An incremental learning method based on probabilistic neural networks and adjustable fuzzy clustering for human activity recognition by using wearable sensors[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2012, 16(4): 691-699.
- [5] Mi Z and Alexander A S. A feature selection-based framework for human activity recognition using wearable multimodal sensor[C]. *Proceedings of International Conference on Body Area Networks*, Beijing, 2011: 201-208.
- [6] Wang L, Gu T, Tao X P, et al.. A hierarchical approach to real-time activity recognition in body sensor networks[J]. *Journal of Pervasive and Mobile Computing*, 2012, 8(1): 115-130.
- [7] Cheng L, Hailes S, Chen Z, et al.. Compressed Inertial motion data in wireless sensing systems—an initial experiment[C]. *Proceedings of 5th International Workshop on Wearable and Implantable Body Sensor Networks(BSN'08)*, Washington, 2008: 293-296.
- [8] Wu C H and Tseng Y C. Data compression by temporal and spatial correlations in a body-area sensor network: a case study in pilates motion recognition[J]. *IEEE Transactions on Mobile Computing*, 2011, 10(10): 1459-1472.

- [8] Ghasemzadeh H and Guenterberg E. Energy-efficient information driven coverage for physical movement monitoring in body sensor networks[J]. *IEEE Journal on Selected Area in Communications*, 2009, 27(1): 58-69.
- [9] Ghasemzadeh H, Loseu V, and Jafari R. Structural action recognition in body sensor networks: distributed classification based on string matching[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2010, 14(2): 425-435.
- [10] Yang Y, Jafari R, Shankar S, *et al.* Distributed recognition of human actions using wearable motion sensor networks[J]. *Journal of Ambient Intelligence and Smart Environments*, 2009, 1(2): 1-5.
- [11] Donoho D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [12] Davenport M A, Boufounos P T, Wakin M B, *et al.* Signal processing with compressive measurements[J]. *IEEE Transactions on Selected Topics in Signal Processing*, 2010, 4(2): 445-460.
- [13] Davenport M, Duarte M, Wakin M, *et al.* The smashed filter for compressive classification and target recognition[C]. *Proceedings of SPIE Computational Imaging V*, San Jose, 2007: 326-330.
- [14] Mamaghanian H, Khaled N, Atienza D, *et al.* Compressed sensing for real-time energy-efficient ECG compression on wireless body sensor nodes[J]. *IEEE Transactions on Biomedical Engineering*, 2011, 58(9): 2456-2466.
- [15] Wright J, Yang Y, Ganesh S, *et al.* Robust face recognition via sparse representation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 210-227.
- [16] Candès E and Tao T. Decoding by linear programming[J]. *IEEE Transactions on Information Theory*, 2005, 51(12): 4203-4215.
- [17] Rauhut H, Schnass K, and Vandergheynst P. Compressed sensing and redundant dictionaries[J]. *IEEE Transactions on Information Theory*, 2008, 54(5): 2210-2219.
- [18] Berg E V and Friedlander M P. SPGL1: a solver for large-scale sparse reconstruction [OL]. <http://www.cs.ubc.ca/labs/scl/spgl1>. 2009.5.
- 肖 玲： 女，1977 年生，博士生，讲师，研究方向为无线传感器网络、体域网。
- 李仁发： 男，1957 年生，博士生导师，教授，主要研究方向为嵌入式计算和 CPS。
- 罗 娟： 女，1974 年生，博士，副教授，主要研究方向为无线传感器网络。