

# 基于 DKP 和 OS-KELM 算法的姿态识别

韩莹<sup>1</sup>, 张浩<sup>1</sup>, 刘健<sup>2</sup>, 陈立平<sup>1</sup>

(1 中国科学院 微电子研究所, 北京 100029; 2 北京科技大学 计算机与通信工程学院, 北京 100029)

**摘 要:** 提出了一种基于智能手机识别人体姿态的神经网络分类器的设计方案. 该设计的主旨是用第一级分类器区分动态和静态动作, 然后用第二级分类器分别识别这两类动作. 第一级分类器采用直接核感知机 DKP(Direct Kernel Perceptron), 其具有简单、快速,  $\alpha$  系数可直接计算得出而无需任何反复训练的特点. 在线序列核极限学习机 OS-KELM(Online Sequential Kernel Extreme Learning Machine)因其高效性被作为第二级分类器. 实验结果成功验证提出的识别方案是可行的.

**关键词:** 在线序列 ELM; 核函数; 直接核感知机; 姿态识别; 模式识别

**中图分类号:** TP31

**文献标识码:** A

**文章编号:** 1000-7180(2017)12-0088-06

## Activity Recognition Based on DKP and OS-KELM Algorithm

HAN Ying<sup>1</sup>, ZHANG Hao<sup>1</sup>, LIU Jian<sup>2</sup>, CHEN Li-ping<sup>1</sup>

(1 Institute of Microelectronics of the Chinese Academy of Sciences, Beijing 100029, China;

2 School of Computer & Communication Engineering, University of Science & Technology, Beijing 100029, China)

**Abstract:** This paper presents a systematic design approach for constructing neural classifiers that are capable of classifying human activities using a smartphone. The philosophy of our design approach is to apply first order classifier that separates dynamic activities from static activities and recognizes these two different types of activities separately using second order classifier. We adopt the direct kernel perceptron(DKP) as first classifier for it is a very simple and fast kernel based classifier whose  $\alpha$ -coefficients are calculated directly, without any iterative training. And online sequential kernel extreme learning machine (OS-KELM) is chosen as the second classifier for its high efficiency. Experimental results have successfully validated the effectiveness of the proposed recognition scheme.

**Key words:** online sequential ELM; kernel function; direct kernel perceptron; activity recognition; pattern recognition

## 1 引言

过去十年, 姿态识别已经发展成一个重要的研究领域, 越来越多的应用依赖于感知和识别用户的动作, 例如健康和环境监控应用、居家和工业自动化应用, 以及安全和监控应用等. 虽然人体姿态识别已经被广泛研究, 但是基于智能手机的姿态识别却是一个新领域. 智能手机作为载体, 拥有丰富的传感器, 如加速度计、陀螺仪、GPS 等, 为更高效、更舒适的姿态识别提供了可能<sup>[1]</sup>.

姿态识别的任务是感知物理世界, 主要有两个技术来实现这个目标: 外置传感器和可穿戴传感器. 针对前者, 很多外置设备如每天用得到的简单传感器和摄像头等被用来实现姿态识别. 针对后者, 姿态识别过程中使用很多精小的置于用户体表或者衣服表面的传感器. 随着过去数年技术的发展, 涌现出许多体积更小、价格更低廉、可靠性更高的传感器, 这些内置于智能手机的传感器同样被大量用于采集用户的日常动作信息. 许多使用智能手机实现姿态识别的研究取得了不同的效果<sup>[2]</sup>.

在众多可穿戴传感器中,应用最多的是加速度传感器,其被用来测量人的加速度信号,然后实现日常动作姿态识别<sup>[3]</sup>. 为弥补单一加速度传感器的不足,更多类型的传感器信号被用于姿态识别,如使用加速度和角速度信号<sup>[4]</sup>,使用加速度和压力信号<sup>[5]</sup>,结合三轴加速度计和心电图信号实现姿态识别<sup>[6]</sup>.

类似地,不同的分类算法被用于姿态识别中, Bayesian 和神经网络<sup>[7]</sup>,支持向量机(SVM)<sup>[1]</sup>,在线序列极限学习机(OS-ELM)<sup>[4]</sup>等. 文献[4]中的结论表明,在智能手机上实现姿态识别 OS-ELM 算法具有优越性,其识别精度高的同时,训练时间较其他分类算法更短,并且还具具有在线学习的特点.

然而以上的工作都是基于单级分类器完成的,实验表明进一步提高单一分类器分类性能十分困难,而考虑到被识别的动作(走路、下楼、上楼、站立、坐和躺)主要可以分为静态和动态两类,希望通过很少的特征、很少的计算量就可以实现动态和静态的划分,然后每一类里面的模式用更多的特征去更细致地区分,级联结构能够解决这个问题,并且降低运算复杂度. 本文提出一种两级分类系统 DKP-OS-KELM. 首先使用信号幅度区 SMA(Signal Magnitude Area)和平均能量 AE(Average Energy)<sup>[8]</sup>特征把动作分为动态、静态两大类,这一级分类器使用直接核感知机(DKP)<sup>[9]</sup>算法,它拥有媲美极限学习机 ELM(Extreme Learning Machine)<sup>[10]</sup>的分类精度、极简单输出形式和快速的训练速度等优点,因此被用来作为一级分类器;一级分类后,姿态特征分别进入动态/静态二级分类器进行训练和测试,这一级分类算法采用在线序列核极限学习机(OS-KELM)<sup>[11]</sup>,它继承了 ELM 的训练快的优点,同时具有核函数和在线学习的特点.

2 系统模型

在一个级联模式识别系统中,通常没有必要让每个分类器都对大量特征进行分类,我们期望的是一级分类器用最少的特征区分出动态或是静态,二级分类器用更多的特征实现精确分类. 为此我们提出 DKP-OSKELM 分类器,该模型包含两级:一级 DKP 分类器结构和二级 OSKELM 分类器结构. 首先通过智能手机的传感器(加速度计和陀螺仪)采集数据,然后经过高通滤波器和分窗等预处理,提取特征. 通过一级分类器,我们能区分出动态和静态动作. 然后分别用动态和静态动作模式特征训练二级分类器. 系统整体框图如图 1 所示.




图 1 姿态识别系统整体框架图

2.1 一级 DKP 分类器

图 2 所示的是一级 DKP 分类器结构框图,分类器的输入是加速度和角速度数据经过预处理后提取出的特征. (1) SMA (Signal Magnitude Area): SMA 等于三轴信号幅值在固定窗上归一化总和.

$$SMA = \frac{1}{\omega} \left( \sum_{i=1}^{\omega} |x_i| + \sum_{i=1}^{\omega} |y_i| + \sum_{i=1}^{\omega} |z_i| \right) \tag{1}$$

式中, $\omega$ 是窗口长度; $x_i$ 、 $y_i$ 和 $z_i$ 分别是窗中 $x$ 、 $y$ 和 $z$ 轴的加速度(角速度)样本. (2)AE(Average Energy):能量是窗中信号的离散 FFT 分量幅值平方的总和,我们采用能量的平均值作为特征. 注意到 SMA 和 AE 都是标量,当人处于静态动作组(坐、站立、躺)时上述特征会非常小,反之就处于动态动作组.




图 2 一级分类器结构图

2.2 二级 OS-KELM 分类器

动作经过一级分类后,得到静态/动态标签,再根据标签分别进入各自的二级分类器. 二级 OS-KELM 分类器结构如图 3 所示,其输入是动态(静态)动作的特征.




图 3 二级分类器结构图

这样做的一个优势就是静态/动态的 OSKELM

分类器具有不同的参数,可以更专注区分每个小组的动作模式,提高分类精度.

### 3 算法原理

#### 3.1 DKP 算法

相对于 SVM 和 ELM,DKP 是一个极简且快速的基于核的分类器,其  $\alpha$  系数不需要任何反复的训练,可以通过分析表达式直接计算得出.从文献[9]的结论可知,DKP 具有媲美 ELM 和 SVM 的分类精度和速度,其中基于线性核的 DKP 在二分类问题体现出更高的分类精度,并且省去了反复调整 ELM 隐层大小  $L$  和 SVM 规整参数  $C$  的过程,同时具有极其简洁的输出表达.这给我们的第一层分类提供了一个很好的思路.

用  $y(\mathbf{x}) = \text{sgn}(\mathbf{w}^T \mathbf{x})$  表示一个线性二分类器的输出,  $(\text{sgn}(\cdot))$  是二极函数,  $\mathbf{x}, \mathbf{w} \in R^n$  是归一化的输入模式和权重矢量,  $n$  是输入空间维数.  $x_i$  和  $d_i \in \{\pm 1\}$   $i = 1, 2, \dots, N$  分别表示第  $i$  个训练模式和它的期望输出,  $N$  是训练模式的数量.基于 p-delta 规则,感知机的权重矢量  $\mathbf{w}$  不仅在训练模式  $\mathbf{x}_i$  的输出  $y(\mathbf{x}_i) = \text{sgn}(\mathbf{w}^T \mathbf{x}_i)$  错误 ( $d_i \mathbf{w}^T \mathbf{x}_i < 0$ ) 时更新,也在输出接近错误 ( $d_i \mathbf{w}^T \mathbf{x}_i$  为正但是接近 0) 时更新,即分类器只有在大于某个阈值 ( $d_i \mathbf{w}^T \mathbf{x}_i > \gamma$ ) 时才算分类正确.定义模型总误差为

$$E(\mathbf{w}) = f\left(\frac{\mathbf{Z}^T \mathbf{w}}{|\mathbf{w}|} - \gamma \mathbf{1}\right) \mathbf{1} \quad (2)$$

式中,  $f(\mathbf{v}) \equiv [f(v_1), \dots, f(v_n)]^T$ ,  $f(v_i)$  定义为  $\mathbf{x}_i$  的分类器误差,  $\mathbf{v} \equiv \mathbf{Z}^T \mathbf{w} / |\mathbf{w}| - \gamma \mathbf{1}$ .  $\mathbf{Z}$  是一个  $n \times N$  的矩阵  $\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_N]$ , 其中第  $i$  列  $\mathbf{z}_i \equiv d_i \mathbf{x}_i$ .  $E$  对  $\mathbf{w}$  微分等于 0, 得到:

$$\frac{dE}{d\mathbf{w}} = \frac{(|\mathbf{w}|^2 \mathbf{I} - \mathbf{w} \mathbf{w}^T)}{|\mathbf{w}|^3} \cdot \mathbf{Z} \cdot g\left(\frac{\mathbf{Z}^T \mathbf{w}}{|\mathbf{w}|} - \gamma \mathbf{1}\right) = 0 \quad (3)$$

式中,  $g(\mathbf{v}) \equiv [g(v_1), \dots, g(v_n)]^T$ ,  $g(v_i) \equiv f'(v_i)$ .

对上式进行求解,得到  $\mathbf{w}$  的通解如下:

$$\mathbf{Z} \cdot g\left(\frac{\mathbf{Z}^T \mathbf{w}}{|\mathbf{w}|} - \gamma \mathbf{1}\right) = \lambda \frac{\mathbf{w}}{|\mathbf{w}|} \quad (4)$$

自由参数  $\lambda$  可以通过的  $\mathbf{w}/|\mathbf{w}|$  一范数和  $g$  函数计算得到.

引入非线性核函数  $\Phi(\mathbf{x})$  后感知机输出可由特征空间权重矢量  $\mathbf{w}$  表示为

$$y(\mathbf{x}) = \text{sgn}[\mathbf{w}^T \Phi(\mathbf{x})] \quad (5)$$

在特征空间矩阵  $\mathbf{Z}$  里元素  $z_i = d_i \Phi(\mathbf{x}_i)$  的值是未知的,所以权重矢量  $\mathbf{w}$  也就不能仅据此计算得出.

根据 SVM 里面常用的方法,权重矢量可以写成下面的形式 ( $|\mathbf{w}|$  因子的引入是为了简化求解  $\mathbf{w}$ ):

$$\frac{\mathbf{w}}{|\mathbf{w}|} = \sum_{i=1}^N \alpha_i d_i \Phi(\mathbf{x}_i) = \sum_{i=1}^N \alpha_i \mathbf{z}_i = \vec{\mathbf{Z}} \alpha \quad (6)$$

将式(6)和  $\text{sgn}[\mathbf{w}^T \Phi(\mathbf{x})] = \text{sgn}[\mathbf{w}^T \Phi(\mathbf{x}) / |\mathbf{w}|]$  带入式(5),可得 DKP 输出  $y(\mathbf{x}) = \text{sgn}[\vec{\alpha}^T \mathbf{Z}^T \Phi(\mathbf{x})]$ .

接着定义  $\Phi(\mathbf{x}_1)^T \Phi(\mathbf{x}_2) = K(\mathbf{x}_1, \mathbf{x}_2)$  (如 Gaussian 核  $K(\mathbf{x}_1, \mathbf{x}_2) = \exp(-|\mathbf{x}_1 - \mathbf{x}_2|^2 / \sigma^2)$ ) 并把矩阵展开:

$$\begin{aligned} \mathbf{Z}^T \Phi(\mathbf{x}) &= \begin{bmatrix} d_1 \varphi_1(\mathbf{x}_1) & \cdots & d_1 \varphi_m(\mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ d_N \varphi_1(\mathbf{x}_N) & \cdots & d_N \varphi_m(\mathbf{x}_N) \end{bmatrix} \begin{bmatrix} \varphi_1(\mathbf{x}) \\ \vdots \\ \varphi_m(\mathbf{x}) \end{bmatrix} \\ &= \begin{bmatrix} d_1 \sum_{i=1}^n \varphi_i(\mathbf{x}_1) \varphi_i(\mathbf{x}) \\ \vdots \\ d_N \sum_{i=1}^n \varphi_i(\mathbf{x}_N) \varphi_i(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} d_1 K(\mathbf{x}_1, \mathbf{x}) \\ \vdots \\ d_N K(\mathbf{x}_N, \mathbf{x}) \end{bmatrix} \end{aligned}$$

则输出可表示为  $y(\mathbf{x}) = \text{sgn}[\sum_{i=1}^N \alpha_i d_i K(\mathbf{x}_i, \mathbf{x})]$ , 其表达式和 SVM 的输出一样,但是由后续推导可知  $\vec{\alpha}$  仅通过输入空间的训练模式  $\mathbf{x}_i$  就能直接计算得出,而不是特征空间的特征模式.将式(6)带入  $\mathbf{w}$  的通解(方程(4))可得:

$$g(\vec{\mathbf{P}} \vec{\alpha} - \gamma \mathbf{1}) = \lambda \vec{\alpha} \quad (7)$$

式中,  $\mathbf{P}$  为输入空间  $N \times N$  阶方阵,  $\mathbf{P} \equiv \mathbf{Z}^T \mathbf{Z}$ . 通过式子(7) 矢量  $\vec{\alpha}$  可以直接从矩阵  $\mathbf{P}$  计算得出,  $\mathbf{P}$  只包含输入空间核函数值  $K(\mathbf{x}_i, \mathbf{x}_j)$ , 而非特征空间未知模式,所以  $\vec{\alpha}$  仅通过输入空间的训练模式  $\mathbf{x}_i$  就能计算得到.最后参数  $\lambda$  可以通过约束  $|\mathbf{w}/|\mathbf{w}|| = |\vec{\mathbf{Z}} \vec{\alpha}| = 1$  计算得出.

分类误差函数  $f(\cdot)$  必须是一个非增函数,可以是线性函数、二次函数等,文献[9]中指出线性核 DKP 的效率远远高于二次核 DKP,本文基于效率考虑,采用简单的线性核 DKP 算法作为一级分类器算法.

#### 3.2 OS-KELM 算法

OS-ELM 已被用于处理不同的隐层神经元类型,包括 sigmoid、RBF、多项式等,OS-KELM 填补了 SLFN 隐层神经元类型扩展到核函数的空缺,其在多类分类问题上相较传统 ELM,多了序列学习的

能力以及基于核的算法的优势,同时相较其他在线序列基于核学习算法(如 LASVM<sup>[12]</sup>、BSDG<sup>[13]</sup>), OS-KELM 在运算效率方面体现出更少训练时间<sup>[14]</sup>. 这是本文选择使用 OS-KELM 作为二级 OS-KELM 分类器算法的原因.

给定训练数据集

$N = \{x_i, t_i \mid x_i \in R^m, t_i \in R^l, i = 1, 2, \dots\}$ , 基于核的 SLFN 通用输出可以表达如下<sup>[14]</sup>:

$$f_L(x) = \sum_{i=1}^L \beta_i \kappa(x, x_i) = K_L \beta \tag{8}$$

$\kappa(x, x_i)$  是隐层神经元,  $\beta = [\beta_1, \dots, \beta_L]^T$  是输出权重矢量,  $L$  是隐层神经元数量. 一种更紧凑的表达方式如方程(9):

$$K_L \beta = T \tag{9}$$

由 KKT 理论, 可以求出输出权重

$$\beta = G K_L^T T \tag{10}$$

式中,  $G = (I/C + K^T K)^{-1}$ , 批处理 KELM 假设所有的数据可一次性用来训练, 但是在很多实际应用中数据可能是一块一块获取(一个一个数据模式是一块一块的特殊形式). 这种形式的 KELM 叫做在线序列核极限学习机(OS-KELM)算法. 该算法分两个步骤, 第一步和 KELM 算法一致, 唯一区别是初始化的训练数据只是整个训练集的一部分, 输出矢量也只是初始化隐层矩阵. 第二步是一个迭代过程称为序列化学习的过程. 这步处理序列训练数据

块  $N_{k+1} = \{(x_i, t_i)\}_{j=0}^{k+1}$ , 其中  $N_{k+1}$  代

$$i = \left(\sum_{j=0}^k N_j\right) + 1$$

表第  $(k+1)$  次加入的数据. 每次获取到新的数据, 计算新的隐层神经元矩阵  $K_{k+1} = \kappa(X_{k+1}, X_L)$ , 然后根据文献[11] 计算得到输出权重矢量.

$$\begin{aligned} \beta^{(k+1)} &= \beta^{(k)} + G_{k+1} K_{k+1}^T (T_{k+1} - K_{k+1} \beta^{(k)}) \\ G_{k+1} &= G_k - G_k K_{k+1}^T (I + K_{k+1} G_k K_{k+1}^T)^{-1} K_{k+1} G_k \end{aligned} \tag{11}$$

整个过程直到最后一帧数据训练后结束.

4 实验及结果分析

4.1 实验数据

本实验中, 测试数据选自 UCI<sup>[15]</sup> 手机采集的用于姿态识别的数据集. 一共采集了 10 299 组数据(包含走路、上楼、下楼、坐、站立和躺 6 种动作). 把数据集随机分成无重叠的三个部分, 50% 用于训练、25% 用于验证、25% 用于测试. 用训练数据集训练分

类器, 然后用测试数据集计算分类精度. 验证数据集用于选择参数(如 DKP 里面 Gaussian 核中的  $\sigma$ , OS-KELM 中的隐层神经元  $L$  和规整参数  $C$  等).

训练 DKP 分类器时, 用前文提到的 AE 和 SMA 作为输入特征.

训练 OS-KELM 时, 利用文献[16]的特征选择方法对已有特征集进行选择, 最后得到的特征子集中包含加速度的均值、标准差、最大值、最小值、能量、加速度与重力的夹角等, 角速度的标准差、最大值、最小值、能量、四分差等 64 个特征. 本文使用线性核( $k(x, y) = x^T y$ )和高斯核( $k(x, y) = \exp(-|x - y|^2 / \sigma^2)$ )作为 OS-KELM 算法的核函数.

本文比较了单级 OS-KELM 分类器和两级 DKP-OSKELM 分类器分类精度, 以及同一种分类器中线性核和高斯核对结果的影响.

4.2 结果分析

DKP-OSKELM 分类器的第一级将数据分为静态和动态两类, 高斯核的参数  $\sigma$  从  $\{2^{-15}, 2^{-14}, \dots, 2^3\}$  中进行选择验证, 表 1 所示的是 6 类动作经过第一级 DKP 分类器后的分类结果, 第一行总共有 442 组走路数据被测试, 所有走路模式都被正确分类到动态组, 第四行总共有 457 组坐的数据被测试, 有 453 组模式被正确分到静态组, 有 4 组模式被错误分到动态组. 其余数据以此类推. 第一列动态分类结果中, 总共有 1 199 组数据被测试, 有 1 183 组模式被正确分类, 分类精度为 98.67%, 第二列静态分类结果中, 总共有 1 376 组数据被测试, 全部被正确分类, 分类精度为 100%. 综合得出第一级分类精度为 99.33%. 也就说明第一级分类结果非常理想, 数据经过第一级分类器后, 会进入相应的第二级 OS-KELM 分类器.

表 1 一级 DKP 分类器分类结果表

| 数据标签 | 分类为动态 | 分类为静态 |
|------|-------|-------|
| 走路   | 442   | 0     |
| 上楼   | 389   | 0     |
| 下楼   | 352   | 0     |
| 坐    | 4     | 453   |
| 站立   | 2     | 438   |
| 躺    | 10    | 485   |
| 精度/% | 98.67 | 100   |

二级 OSKELM 分类器的最佳神经元个数  $L$  和规整化参数  $C$  需要被交叉验证, 简单起见, 这里只介绍如何选择最佳神经元个数  $L$ , 用训练集数据进

行训练然后用验证集数据交叉验证,最优  $L$  应满足验证误差最小. OS-KELM 识别精度随神经元个数不同的变化趋势如图 4 所示. 可以看出 OS-KELM 分类精度先随着神经元数量增加而明显递增,达到某一拐点后不再随神经元数量增加而提高. 线性核 OS-KELM 出现拐点的位置比高斯核 OS-KELM 早,对于 OS-KELM(线性核)选择 50 个神经元,而 OS-KELM(高斯核)选择 100 个神经元是合适的.




图 4 神经元个数对 OS-KELM 精度影响

接着我们比较两级 DKP-OSKELM 分类器和单级的 OS-KELM 分类器的分类精度,同时也对线性核和高斯核不同内核的分类器精度进行比较,结果如表 2 所示. OS-KELM(线性核)和 OS-KELM(高斯核)的平均分类精度分别为 90.96%和 92%,DKP-OSKELM(线性核)和 DKP-OSKELM(高斯核)的平均分类精度分别为 92.48%和 95.66%. 可以看出在加入一级 DKP 分类器以后,分类精度分别提高了 1.52%和 3.66%,这说明加入一级 DKP 分类器是有效的.

在 OS-KELM 里,高斯核对各个动作(除了躺)的分类精度比线性核要高,平均分类精度高出 1.04%. 而在 DKP-OSKELM 算法中,每个动作高斯核分类精度都比线性核要高,平均精度高出 3.81%. 这说明所选内核不同对分类器最后的分类精度也有影响,总体来说高斯核的分类精度比线性核更高.

表 2 不同分类器分类精度表

| 算法  | OS-KELM<br>(Lin) | OS-KELM<br>(Gaus) | DKP-OSKELM<br>(Lin) | DKP-OSKELM<br>(Gaus) |
|-----|------------------|-------------------|---------------------|----------------------|
| 走路  | 90.97            | 90.52             | 93.45               | 95.03                |
| 上楼  | 90.38            | 90.93             | 94.78               | 95.88                |
| 下楼  | 90.91            | 92.67             | 96.48               | 97.07                |
| 坐   | 84.27            | 88.99             | 83.60               | 93.03                |
| 站立  | 89.66            | 92.25             | 88.87               | 95.23                |
| 躺   | 99.58            | 96.66             | 97.70               | 97.70                |
| 平均值 | 90.96            | 92.00             | 92.48               | 95.66                |

除了分类精度,训练和测试时间也是评价一个分类器的标准,表 3 显示的是 OS-KELM 和 DKP-OSKELM 基于线性和高斯核的训练和测试时间. 通过结果可看出高斯核的训练时间和测试时间都比线性核要多,其中不论 OS-KELM 还是 DKP-OSKELM 在使用线性核函数的时候,训练时间分别为 0.297 s 和 0.27 s,相对高斯核的 1.969 s 和 2.019 s,所需时间都缩短约 7 倍,这是使用线性核的优势. 如果希望算法分类精度更高而不计较时间可以选择高斯核,相反期望更短的时间可以牺牲一点精度的话线性核是更好的选择. 第一级 DKP 分类器的加入也导致了训练时间的增加,我们也可看出线性核和高斯核单级 OS-KELM 分类器测试时间分别为 0.02 s 和 0.234 s,两级 DKP-OSKELM 分类器的测试时间分别为 1.744 s 和 1.807 s,测试时间都有所增加,这是加入 DKP 分类器的代价. 系统运行环境为 MATLAB 2015b/Intel i5 2.3 G 处理器.

表 3 不同分类算法训练和测试时间比较

| 分类算法             | 训练时间  | 测试时间  |
|------------------|-------|-------|
| OSKELM(Lin)      | 0.270 | 0.020 |
| OSKELM(Gaus)     | 1.969 | 0.234 |
| DKP-OSKELM(Lin)  | 0.297 | 1.744 |
| DKP-OSKELM(Gaus) | 2.019 | 1.897 |

5 结束语

本文提出了 DKP-OSKELM 两级分类器方案实现对人走路、上楼、下楼、坐、站立、躺的识别,同时比较了线性核和高斯核对分类结果的影响. 在加入了一级 DKP 分类器后,相比单级 OS-KELM 同核分类器精度分别提高了 1.52%和 3.66%,证明本方案对提高分类精度是有效的. 实验结果同时表明,DKP-OSKELM 的线性核分类器精度没有高斯核精度高,但是训练时间大大缩短. 随着一级 DKP 分类器的加入,DKP-OSKELM 的训练时间和测试都有所增加.

本文使用 OS-KELM 和 DKP-OSKELM 算法对人的姿态分类识别进行了探索,考虑进一步的研究方向如下(1) DKP-OSKELM 两级分类器方案虽然实现了精度的提高,但是这个系统存在一级分类错误扩散到二级的隐患,即使从一级 DKP 分类器分类精度高达 99.33%,但是无法避免的会将错误带到二级分类器当中,可以考虑增加二级分类器单独识别一级识别错误的模式;(2)现在动态(静态)动

作分类用的同一个特征集,这两类可以考虑分别用不同的特征集去描述;(3)可以更进一步探索不同的核函数对识别精度和训练时间的影响,同时可以考虑用多核来弥补单核的缺陷。

### 参考文献:

- [1] Khan A M, Tufail A, Khattak A M, et al. Activity recognition on smartphones via sensor-fusion and KDA-based SVMs[J]. International Journal of Distributed Sensor Networks, 2014(1):1-14.
- [2] Lara O D, Labrador M A. A survey on human activity recognition using wearable sensors[J]. IEEE Communications Surveys & Tutorials, 2013, 15 (3): 1192-1209.
- [3] Fuentes D, Gonzalez-Abril L, Angulo C, et al. Online motion recognition using an accelerometer in a mobile device[J]. Expert systems with applications, 2012, 39(3): 2461-2465.
- [4] Al Jeroudi Y, Ali M A, Latief M, et al. Online sequential extreme learning machine algorithm based human activity recognition using inertial data[C]//Control Conference (ASCC), 2015 10th Asian. IEEE, 2015: 1-6.
- [5] Song Y, Liu Z, Wang J. Human daily activity recognition based on online sequential extreme learning machine[C]//Intelligent Control and Automation (WICA), 2016 12th World Congress on. IEEE, 2016: 3226-3229.
- [6] Fujimoto T, Nakajima H, Tsuchiya N, et al. Wearable human activity recognition by electrocardiograph and accelerometer [C]//Multiple Valued Logic (ISMVL), 2013 IEEE 43rd International Symposium on. IEEE, 2013:12-17.
- [7] Bu N, Okamoto M, Tsuji T. A hybrid motion classification approach for EMG-based human-robot interfaces using bayesian and neural networks[J]. IEEE Transactions on Robotics, 2009, 25(3): 502-511.
- [8] Yang J Y, Wang J S, Chen Y P. Using acceleration measurements for activity recognition: An effective learning algorithm for constructing neural classifiers[J]. Pattern recognition letters, 2008, 29(16): 2213-2220.
- [9] Fernandez-Delgado M, Cernadas E, Barro S, et al. Direct Kernel Perceptron (DKP): ultra-fast kernel ELM-based classification with non-iterative closed-form weight calculation[J]. Neural networks : the official journal of the International Neural Network Society, 2014, 50:60-71.
- [10] Huang G B, Zhou H, Ding X, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42 (2): 513-529.
- [11] Deng W Y, Ong Y S, Tan P S, et al. Online sequential reduced kernel extreme learning machine[J]. Neurocomputing, 2016, 174:72-84.
- [12] Lin K M, Lin C J. A study on reduced support vector machines[J]. IEEE transactions on Neural Networks, 2003, 14 (6): 1449-1459.
- [13] Wang Z, Crammer K, Vucetic S. Breaking the curse of kernelization: Budgeted stochastic gradient descent for large-scale svm training[J]. Journal of Machine Learning Research, 2012, 13 (10): 3103-3131.
- [14] Scardapane S, Comminiello D, Scarpiniti M, et al. Online sequential extreme learning machine with kernels[J]. IEEE transactions on neural networks and learning systems, 2015, 26 (9): 2214-2220.
- [15] Anguita D, Ghio A, Oneto L A. A public domain dataset for human activity recognition using smartphones[EB/OL]. [2017-01-11]. <http://archive.ics.uci.edu/ml/datasets/Human+Activity+Recognition+Using+Smartphones>.
- [16] Peng H L F, Ding C. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy[J]. IEEE Computer Society, 2005, 27 (8): 1226-1238.

### 作者简介:

**韩莹女**, (1991-), 硕士研究生. 研究方向为数字信号处理、无线通信。

**张浩(通讯作者)** 男, (1975-), 副研究员. 研究方向为复杂环境下的线性和非线性信号处理技术。

E-mail: haozhang@ime.ac.cn.

**刘建男**, (1977-), 副教授. 研究方向为信号处理、认知无线网络、移动网网络、物联网技术。

**陈立平男**, (1983-), 助理研究员. 研究方向为信号处理、无线通信。