

## 基于 HMM 的动作识别结果可信度计算方法

王昌海, 张建忠, 徐敬东, 许昱玮

(南开大学计算机与控制工程学院, 天津 300350)

**摘要:** 针对当前动作识别可信度计算方法中混淆率高、不适用于迁移学习等问题, 提出一种基于样本上下文信息的可信度计算方法(S-HMM, sliding windows hidden Markov model)。该方法使用隐马尔可夫模型(HMM, hidden Markov model)理论对识别结果序列建模, 将样本所在序列识别正确的概率作为识别结果的可信度, 避免了当前可信度计算方法依赖于样本在特征空间中分布的问题。实验使用真实场景中的数据进行仿真, 结果表明, 与现有方法相比, 该方法可将可信度混淆率降低 37% 左右。

**关键词:** 动作识别; 隐马尔可夫模型; 混淆率; 可信度

**中图分类号:** TP399

**文献标识码:** A

## Identifying the confidence level of activity recognition via HMM

WANG Chang-hai, ZHANG Jian-zhong, XU Jing-dong, XU Yu-wei

(College of Computer and Control Engineering, Nankai University, Tianjin 300350, China)

**Abstract:** A context-based method to identify the confidence level of activity recognition was proposed, referred to as S-HMM (sliding window hidden Markov model), which reduced the confusion rate and facilitated the transfer learning. With S-HMM, the activity recognition sequence was modeled as HMM(hidden Markov model)and the corresponding probability was adopted as the confidence level. This , S-HMM removed the dependency of the confidence level on the sample distribution in the feature space. S-HMM is extensively evaluated based on real-life activity data, demonstrating a reduced confusion rate of 37% when compared to the state-of-the-art methods.

**Key words:** activity recognition, hidden Markov model, confusion rate, confidence level

### 1 引言

#### 1.1 研究意义

近年来, 基于运动传感器的人体动作识别<sup>[1,2]</sup>成为学术界与工业界的研究热点。研究者通过加速计、陀螺仪等传感器采集人体的运动数据, 并利用这些数据识别用户诸如走路、上楼梯、下楼梯等动作。该研究成果被广泛应用于健康监控<sup>[3]</sup>、惯性导航<sup>[4]</sup>、用户行为跟踪<sup>[5]</sup>等领域。为了更准确地识别人体动作, 研究者已经从特征提取<sup>[6]</sup>、分类算法<sup>[7]</sup>、后处理<sup>[8]</sup>等几个方面开展了诸多研究。然而任何一种方法都无法保证结果完全正确。因此, 在计算识

别结果的同时, 分析每一个结果识别正确的可能性是一个非常有意义的问题。在动作识别领域中, 动作识别正确的可能性称为可信度<sup>[9,10]</sup>。它定义为 0 到 1 之间的实数值, 值越小动作识别正确的概率越小; 反之, 动作识别正确的概率越大。可信度的概念在实际应用中有非常重要的作用, 比如, 室内定位<sup>[4]</sup>需要选择可信度较高的动作推测用户的行进轨迹, 从而提高定位精度; 动作识别迁移学习<sup>[11]</sup>需要选择可信度较高的识别结果更新原始分类器, 从而提高迁移后的动作识别率。

#### 1.2 研究动机

当前, 可信度的计算主要基于原有的分类算

收稿日期: 2015-06-26; 修回日期: 2015-12-18

基金项目: 高等学校博士学科点专项科研基金资助项目(No.20120031110035); 天津市重大科技专项基金资助项目(No.13ZCZDZX01098)

**Foundation Items:** Research Fund for the Doctoral Program of Higher Education of China (No. 20120031110035), The Key Project in Tianjin Science & Technology Pillar Program (No.13ZCZDZX01098)

法,如决策树<sup>[12]</sup>通过样本所属的叶子节点在剪枝时不同类别样本的比例得出; $k$  近邻法<sup>[13]</sup>通过最近  $k$  个样本中不同类别样本的比例得出;支持向量机<sup>[14]</sup>、神经网络<sup>[9,10]</sup>通过样本分类结果的权值得出等。这些方法有一个共同特点,即可信度依赖于待分类样本在特征空间中的分布。如果待分类样本距离分类边界较近,则计算得到的可信度较低;反之,可信度较高。上述方法在当前一些应用中取得了不错的效果,但是在迁移学习<sup>[11]</sup>领域中,该方法存在局限性。

以手机位置自适应的人体动作识别为例,由于不同身体位置数据的差异性,通过智能手机采集到的同类动作样本分布在特征空间的不同区域。假设采自人体 2 个不同位置(裤兜、上衣兜)的 2 个动作(走路、上楼)样本分布如图 1 所示。




图 1 同类动作不同位置的样本分布

如图 1 所示,手机位于裤兜中时样本分布在区域 1 和区域 2,手机位于上衣兜时样本分布在区域 3 和区域 4。原始分类器使用区域 1 和区域 2 中的样本训练得到,分类边界如边界 1 所示。动作识别过程中,手机放置在上衣兜。此时使用原始分类器对区域 3 和区域 4 中的动作分类时识别率较低。为了实现手机位置的自适应,需要在识别结果中尽可能选择识别正确(即可信度高)的样本更新原始分类器,以得到新的分类边界如边界 2 所示。根据分类器的原理,重训练样本距离区域 3 和区域 4 的中心越近,更新后的分类边界越接近边界 2。但是根据基于样本分布的可信度计算方法原理,分类结果的可信度越高,样本距区域 1 和区域 2 的中心越近,而这些样本往往处于区域 3 和区域 4 的边缘。这就导致可信度较高的样本反而不利于提高更新后分类器的识别率。因此,提出一种不依赖于样本分布的可信

度方法是十分必要的。

进一步考虑动作识别的实际应用场景,某样本往往与其前后样本有非常紧密的联系。比如,当前样本为走路时,前后样本也为走路的可能性较大。当前样本为上楼时,前后样本为下楼的可能性较小等。从另外一个角度说,如果识别结果序列在实际应用场景中频繁出现,则该序列中的样本识别正确的可能性较大;反之,该序列中出现错误识别结果的可能性较大。即识别结果序列在实际场景中出现的概率可以为识别结果可信度的计算提供参考。由于该参考信息与样本在特征空间中的分布无关,因此,使用序列概率计算可信度可克服现有方法的缺陷。本文使用 HMM 理论对识别结果序列建模,并使用该理论计算序列识别正确的概率。

### 1.3 HMM 的相关应用

HMM<sup>[15,16]</sup>理论在动作识别领域已经有诸多应用。针对不同的场景,其应用形式也不同。在基于视频的动作识别<sup>[17,18]</sup>中,HMM 用于对帧的特征序列建模,通过计算序列的最大似然概率识别当前动作;在智能家居<sup>[19]</sup>研究中,HMM 用于对识别结果序列建模,并使用序列标注算法识别当前动作;在智能护理<sup>[20,21]</sup>领域中,HMM 用于描述动作识别结果序列,通过计算序列出现的概率检测是否出现异常动作;在基于移动设备的动作识别研究中,HMM 用于对识别结果序列做后处理<sup>[8]</sup>,以提高动作识别率。

上述研究表明,将 HMM 理论应用于动作识别领域已取得较好的成效。然而,当前还没有使用 HMM 理论计算识别结果可信度的研究。针对当前可信度计算方法中存在的问题,本文提出了基于 HMM 的动作识别结果可信度计算方法 S-HMM。该方法使用 HMM 计算结果序列识别正确的概率,并将该概率作为识别结果的可信度。与当前基于分类器的方法相比,该方法可将识别结果可信度的混淆率降低 37%左右。

## 2 本文的可信度方法

本节首先介绍 S-HMM 的流程,然后依次详细介绍 S-HMM 中使用的 HMM 参数及概率计算公式。

### 2.1 S-HMM 的主要流程

计算识别结果的可信度之前,需要根据原始运动数据识别人体的动作,该过程是 S-HMM 的基础。识别的过程包括原始数据的窗口划分、特征提取、分类器训练、动作分类等 4 个步骤。采集到原始运

动数据后，首先将数据划分成固定长度的窗口，每一个窗口称为一个样本。然后对样本提取特征。分类器的训练集记为  $D_{train}=\{(x_1,t_1),(x_2,t_2),\dots,(x_N,t_N)\}$ ，其中， $x_i$  为样本  $i$  的特征， $t_i$  为样本的动作类别。动作分类过程中，给定分类器待分类样本的特征  $y_i$ ，分类器将计算出该样本所属的动作类别  $o_i$ 。对于实际应用场景中采集到的原始数据，通过该过程可以得到一串连续的动作识别结果序列，记为  $o=\{o_1,o_2,o_3,\dots,o_m\}$ 。

为了利用上下文信息判断样本是否识别正确，需要考虑一个包含某样本与其若干相邻样本的识别结果子序列，将该序列识别正确的概率作为判断序列中样本是否识别正确的依据。对于整个识别结果序列，由于每一个样本都被包含在多个子序列中，而每一个子序列识别正确的概率对该样本的可信度皆有影响，所以每一个样本需要记录多个序列识别正确的概率，并将这些概率的均值作为其最终的可信度。

由于不同的应用场景中动作转换关系也不同，因此在利用 HMM 对识别结果建模时，需要使用当前场景的识别结果序列  $o$  动态更新 HMM 参数。当前，HMM 的基本理论中提供了用于训练 HMM 参数的 Baum-Welch 算法<sup>[15]</sup>。该算法可以在给定一个观察序列及参数初始猜测值的情况下，学习得到最有可能的 HMM 参数。得到 HMM 参数后，S-HMM 的第二步为使用滑动窗口将识别结果序列划分成固定长度的子序列，并利用 HMM 理论计算每一个子序列识别正确的概率。S-HMM 的最后一步为根据子序列识别正确的概率计算每一个样本识别正确的概率，该概率即为识别结果的可信度。S-HMM 的详细步骤如算法 1 所示。

算法 1 基于 HMM 的动作识别结果可信度计算方法(S-HMM)

输入：识别结果序列  $o$ ，序列长度  $T$ ，滑动窗口长度  $l$ ；

输出：识别结果的可信度  $C$ ；

- 1)  $l = \text{update}(o)$ ; //更新模型参数
- 2)  $C = \text{num} = \text{zeros}(T)$ ;
- 3) for  $i=1:T-l+1$
- 4)  $\text{Seq}_i = o(i:i+l-1)$  ;//子序列划分
- 5)  $P_i = \text{probability}(\text{Seq}_i)$  ;//计算概率
- 6)  $C(i:i+l-1) += P_i$ ;
- 7)  $\text{num}(i:i+l-1) += 1$

- 8) end for
- 9) for  $i=1:T$
- 10)  $C(i) = \frac{C(i)}{\text{num}(i)}$
- 11) end for
- 12) return  $C$

算法 1 子序列划分的一个实例如图 2 所示，其中滑动窗口大小为 3。




图 2 子序列划分实例

如图 2 所示，每一个样本被包含在 3 个子序列中（整个序列的开始和结尾的特殊情况除外）。比如样本  $i+2$ ，它被包含在序列  $\text{Seq}_i$ 、 $\text{Seq}_{i+1}$ 、 $\text{Seq}_{i+2}$  中。该样本识别正确的概率为 3 个子序列识别正确的概率均值。

算法 1 的第 1)步需要使用识别结果序列  $o$  和 Baum-Welch 算法动态更新 HMM 的参数，这些参数将在 2.2 节中介绍。算法的第 3)步为计算指定子序列在当前 HMM 参数下识别正确的概率  $P_i$ ，该概率的计算公式将在 2.3 节中给出。

### 2.2 HMM 的主要参数

HMM 包括 2 种状态：一种是真实发生的不可见状态；另一种是与不可见状态相关的可见状态。状态的集合记为  $S = \{s_1, s_2, \dots, s_n\}$ ，其势为  $n$ 。与动作识别相对应，不可见状态为人体的真实动作，可见状态为通过识别算法识别得到的动作。集合  $S$  包含了人体可能出现的  $n$  种动作。动作识别的 HMM 模型如图 3 所示。




图 3 动作识别的 HMM

在图 3 中,  $a$  为人体真实发生且不可见的动作序列。当  $t=i$  时, 人体的真实动作为  $a_i$  其中,  $a_i \in S$ 。随着时间  $t$  的变化, 人体可能会继续保持当前动作, 也可能会转变为其他动作。不同动作之间的转换概率组成的矩阵称为动作转移矩阵, 它描述了不同动作之间的转换关系。在本文中, 动作的转移矩阵表示如下

$$Q = [q_{ij}]_{n \times n}$$

其中,  $0 \leq q_{ij} \leq 1$ , 且  $\sum_{j=1}^n q_{ij} = 1$ 。  $q_{ij}$  表示当前动作为  $s_i$  时, 下一个动作为  $s_j$  的概率, 即  $q_{ij} = P(a_{i+1} = s_j | a_i = s_i)$ 。

与  $a_i$  相对应的是可观察到的状态  $o_i$ , 它表示  $t=i$  时动作识别算法识别到的人体动作, 其中,  $o_i \in S$ 。动作识别算法的目的是尽可能使  $o_i$  与  $a_i$  相同。但是任何动作识别方法都不能保证所有的  $o_i$  与  $a_i$  都相同, 动作  $s_i$  被识别为动作  $s_j$  的概率称为动作  $s_i$  到动作  $s_j$  的混淆概率。所有动作之间的混淆概率组成的矩阵称为混淆矩阵。在本文中, 动作识别的混淆矩阵表示如下

$$P = [p_{ij}]_{n \times n}$$

其中,  $0 \leq p_{ij} \leq 1$ , 且  $\sum_{j=1}^n p_{ij} = 1$ 。  $p_{ij}$  表示真实动作为  $s_i$  时, 识别得到动作  $s_j$  的概率, 即  $p_{ij} = P(o_i = s_j | a_i = s_i)$ 。除了转移矩阵和混淆矩阵, HMM 中另一个重要参数是初始状态向量。初始状态向量描述了状态  $a_1$  中各种动作出现的概率。本文中, 动作的初始状态向量表示如下

$$p = [b_i]_{1 \times n}$$

其中,  $0 \leq b_i \leq 1$ , 且  $\sum_{i=1}^n b_i = 1$ 。  $b_i$  为状态  $a_1$  时, 动作  $s_i$  出现的概率, 即  $b_i = P(a_1 = s_i)$ 。

### 2.3 序列识别正确的概率的计算

S-HMM 中最重要的一步为计算子序列识别正确的概率  $P_i$ 。假设需要计算  $P_i$  的动作序列为  $o' = \{o_1, o_2, \dots, o_l\}$ , 其长度为  $l$ , 且  $o_i \in S$ 。  $P_i$  实际上是识别结果为序列  $o'$  的情况下, 真实动作也为序列  $o'$  的概率。本文定义 2 个事件, 事件  $A$  为真实动作中出现序列  $o'$ , 事件  $B$  为识别结果中出现序列  $o'$ 。根据后验概率的计算方法,  $P_i$  如式(1)所示。

$$P_i = P(A|B) = \frac{P(A)P(B|A)}{P(B)} \tag{1}$$

其中,  $P(A)$  为真实动作中出现序列  $o'$  的概率;  $P(B|A)$  为真实动作为序列  $o'$  时, 识别结果也为序列  $o'$  的概率, 即序列  $o'$  全部识别正确的概率;  $P(B)$  为识别结果为序列  $o'$  的概率。下面分别计算 3 个概率。

#### 1) $P(A)$

在不考虑序列  $o'$  前后动作的情况下, 序列  $o'$  中第一个动作出现的概率为该动作的初始概率分布, 其值为  $b_{o_1}$ 。第  $i$  个动作与第  $i+1$  个动作之间的转换概率为  $q_{o_i, o_{i+1}}$ , 所以真实动作中出现序列  $o'$  的概率为

$$P(A) = b_{o_1} \prod_{i=1}^{l-1} q_{o_i, o_{i+1}} \tag{2}$$

#### 2) $P(B|A)$

根据混淆矩阵的定义, 每一个不可见动作  $o_i$  识别正确的概率为  $p_{o_i, o_i}$ , 所以有

$$P(B|A) = \prod_{i=1}^l p_{o_i, o_i} \tag{3}$$

#### 3) $P(B)$

$P(B)$  的计算是 HMM 理论<sup>[15]</sup>中的经典问题, 其计算式为

$$P(B) = \sum_{k=1}^n a_i(k) \tag{4}$$

其中,  $a_i(k)$  为递推公式, 如式(5)所示。

$$a_i(k) = \begin{cases} b_k p_{k, o_1}, & i=1 \\ p_{k, o_i} \sum_{j=1}^n a_{i-1}(j) q_{j, k}, & i>1 \end{cases} \tag{5}$$

根据式(1)~式(4), 给定识别结果子序列  $o'$ , 该序列识别正确的概率如式(6)所示。

$$P_i = \frac{b_{o_1} \prod_{i=1}^{l-1} q_{o_i, o_{i+1}} \prod_{i=1}^l p_{o_i, o_i}}{\sum_{k=1}^n a_i(k)} \tag{6}$$

其中,  $a_i(k)$  如式(5)所示。

## 3 仿真实验

虽然当前有动作识别可信度的研究, 但是还没有发现评判可信度方法好坏的标准。为了与当

前方法进行比较，3.1 节中提出了用于评判可信度方法优劣的混淆率的概念。后续几节中以此为基础介绍了实验结果、参数的影响及方法的适用场景。

### 3.1 可信度方法优劣的标准

按照可信度提出的目的，好的可信度计算方法应当赋予识别正确的结果较高的值，且赋予识别错误的结果相对较低的值。此时，通过观察识别结果的可信度即可将识别正确与识别错误的样本区分出来，进而有好的应用效果。相反，如果识别正确的样本与识别错误的样本的可信度接近，则会导致高可信度的样本中存在大量识别错误的样本，无法实现通过可信度判断样本识别正确与否的目的。所以，可以使用识别结果中正确样本的可信度与错误样本的可信度之间的混淆程度即混淆率作为衡量可信度算法好坏的标准。

假设集合  $U$  为所有识别结果可信度的集合， $U = U_1 \cup U_2$ ，其中， $U_1$  为识别错误的样本的可信度集合， $U_2$  为识别正确的样本的可信度集合。集合  $U$  的元素个数为  $n$ ，集合  $U_1$  的元素个数为  $n_1$ ，集合  $U_2$  的元素个数为  $n_2$ 。集合  $U$  的取值范围为  $[\min, \max]$ ，集合  $U_1$  的取值范围为  $[\min_1, \max_1]$ ，集合  $U_2$  的取值范围为  $[\min_2, \max_2]$ 。所有样本的可信度分布如图 4 所示。




图 4 可信度混淆率示意

在计算混淆率之前，需要找到一个最佳划分点  $x$  满足

$$\min \left| \frac{n_{U_1 > x}}{n_1} - \frac{n_{U_2 < x}}{n_2} \right| \quad (7)$$

其中， $n_{U_1 > x}$  为集合  $U_1$  中大于  $x$  的样本个数， $n_{U_2 < x}$  为集合  $U_2$  中小于  $x$  的样本个数。如式(7)所示，如果某一点  $x$  满足大于该点的错误结果的比例与小于该点的正确结果的比例之差最小，那么该点可以将  $U_1$  和  $U_2$  这 2 个集合最好地区分出来。基于该划分点  $x$ ，

混淆率定义如式(8)所示。

$$r = \frac{\frac{n_{U_1 > x}}{n_1} + \frac{n_{U_2 < x}}{n_2}}{2} \quad (8)$$

其取值有如下几种情形。

1)  $r = 0$ 。此时  $U_1 \cap U_2 = \emptyset$  且  $\max_1 < \min_2$ ，即所有错误识别结果的可信度皆小于正确识别结果的可信度，该情形为可信度计算方法的理论最好情况。

2)  $0 < r < 1$ 。此时  $U_1 \cap U_2 \neq \emptyset$ ，即 2 个集合有一定的交集。该情形为可信度计算方法的最常见情况，且  $r$  越小，可信度计算方法越好。

3)  $r = 1$ 。此时  $U_1 \cap U_2 \neq \emptyset$  且  $\min_1 > \max_2$ ，即所有错误结果的可信度皆大于正确结果的可信度，该情形为可信度计算方法的最坏情况。

通过对 3 种情形的分析可得，可信度计算方法的混淆率越小，该方法越好。

### 3.2 数据采集与特征提取

由于本文算法的性能与动作的持续时间及动作之间的转换顺序有关系，而当前公开数据集无法同时满足 2 个条件，即并不适用于本方法的实验，所以在实验之前进行了数据采集。本文中的实验以手机位置自适应的动作识别为研究背景。数据采集设备为小米 2S 智能手机，分别采集运动产生的三轴加速度数据和三轴陀螺仪数据，数据采集的频率为 100 Hz。采集的动作包括走路、上楼、下楼、静止、跑步 5 种。手机的佩戴位置如图 5 所示。



图 5 数据采集的位置

位置 1、2、3、4、6 为手机放置在不同口袋中的情况，位置 5、7、8 为手机拿在手中的情况。数据采集包括训练数据采集和测试数据采集这 2 部分。训练数据中每一种动作单独采集，采集的位置包括 1、4、5、6。测试数据沿一条预先设定好的路径对 8 个佩戴位置进行采集。采集过程中，实时产

生的加速度数据自动保存在手机的存储设备中。采集完成后，数据被复制到 PC 端进行仿真。仿真之前将三轴加速度和三轴角速度进行合成以降低手机方向的影响，然后使用大小为 256 的半重叠滑动窗口对原始数据划分窗口。表 1 列出了训练数据的样本数。

**表 1** 训练数据的样本数

位置	跑步	上楼	下楼	静止	走路
位置 1	94	87	86	87	96
位置 4	82	79	81	78	85
位置 5	88	88	83	71	78
位置 6	97	86	82	88	77
总计	361	340	332	324	336

表 2 列出了测试数据中手机位于位置 1 时，不同动作的样本数及转换关系。其他 7 个佩带位置基本相同。

**表 2** 测试数据的样本数与转换关系

动作	跑步	上楼	下楼	静止	走路
跑步	52	0	0	0	3
上楼	0	54	0	1	3
下楼	0	0	44	0	6
静止	0	1	1	71	3
走路	3	3	5	5	101
总计	55	58	50	77	116

表 2 中前 5 行的第  $i$  行第  $j$  列表示，当前动作为  $s_i$  时下一个动作为  $s_j$  的个数。最后一行为不同动作的窗口总数。

### 3.3 实验结果对比

仿真中，首先使用 4 个位置的样本训练分类器，并分别对每一个位置的测试样本分类，以得到识别结果序列。本文中选用了动作识别中常用的 3 个分类器，分别是 ELM(extreme learning machine)、SVM(support vector machine) 和 BP 神经网络。然后，按照算法 1 计算每一个识别结果的可信度。最后使用式(8)计算分类结果的混淆率。更新 HMM 参数时，初始转移矩阵设置如下

$$Q = |q_{ij}|_{5 \times 5} = \begin{cases} 0.8, i = j \\ 0.05, i \neq j \end{cases}$$

初始混淆矩阵设置为所有位置识别结果混淆矩阵的均值，如表 3 所示。

**表 3** 初始混淆矩阵

动作	跑步	上楼	下楼	静止	走路
跑步	0.947	0.023	0.021	0.000	0.010
上楼	0.010	0.800	0.101	0.000	0.089
下楼	0.040	0.110	0.835	0.000	0.016
静止	0.000	0.000	0.001	0.990	0.009
走路	0.040	0.014	0.009	0.000	0.938

本节实验中 S-HMM 的滑动窗口大小设定为 3。利用式(5)和式(6)计算其识别正确的概率时，不同动作的初始概率相同。表 4 中列出了有训练数据(对位置 1、4、5、6 识别)时，不同分类器及方法的可信度混淆率，其中，W-ELM、W-SVM 和 W-BP 分别为 3 种分类器基于分类结果权值的方法，S-HMM 为本文的方法。

**表 4** 有训练数据时的混淆率

位置	ELM		SVM		BP	
	W-ELM	S-HMM	W-SVM	S-HMM	W-BP	S-HMM
位置 1	0.146	0.071	0.148	0.018	0.136	0.053
位置 4	0.122	0.070	0.153	0.125	0.180	0.110
位置 5	0.183	0.113	0.208	0.163	0.124	0.088
位置 6	0.153	0.131	0.160	0.139	0.157	0.117
平均	0.151	0.096	0.167	0.111	0.149	0.092

从表 4 中可以看出，对于每一种分类器，本文方法的混淆率皆有大幅降低。基于分类器的方法的混淆率为 0.15 左右，使用 S-HMM 时的混淆率为 0.10 左右，总体平均降低了 36.1%。表 5 列出了缺少训练数据(对位置 2、3、7、8 进行识别)时，不同方法的混淆率。

从表 5 中可得，缺少训练数据时基于分类器方法的混淆率为 0.25 左右，S-HMM 的混淆率为 0.16 左右，总体平均降低了 37.2%。对比表 4 和表 5，因为缺少训练数据时动作识别率较低，所以表 5 中不同方法的平均混淆率皆有升高。但是与基于分类器的方法相比，S-HMM 的混淆率有明显降低。

表 5 缺少训练数据时的混淆率

位置	ELM		SVM		BP	
	W-ELM	S-HMM	W-SVM	S-HMM	W-BP	S-HMM
位置 2	0.208	0.118	0.126	0.124	0.177	0.100
位置 3	0.191	0.046	0.160	0.092	0.221	0.111
位置 7	0.300	0.258	0.363	0.269	0.329	0.146
位置 8	0.335	0.227	0.282	0.159	0.361	0.258
平均	0.259	0.163	0.233	0.161	0.272	0.154

观察表 4 和表 5 得，不同分类器使用权值计算得到的可信度混淆率有较大差异，该差异跟分类器在不同数据集下的分类性能有关。如果分类边界附近识别正确的样本数量较多，则可信度的混淆率较高；反之，混淆率较低。同样，不同分类器使用 S-HMM 计算得到的混淆率也有较大不同，它与识别结果序列中错误结果出现的位置有关。如果识别错误的样本分布集中，则易导致混淆率较高；反之，混淆率较低。但总体来说，与基于分类器的方法相比，S-HMM 可将混淆率降低 37% 左右。

### 3.4 S-HMM 中滑动窗口大小的影响

S-HMM 需要使用滑动窗口技术将识别序列划分成固定长度的子序列，以便使用式(6)计算识别正确的概率。本节主要探讨滑动窗口长度对混淆率的影响。图 6 所示为手机位于位置 1、5、8 时，随窗口长度的变化，混淆率的变化情况。其他位置曲线的变化趋势基本相同。




图 6 可信度混淆率与窗口长度的关系

从图 6 中可得，随窗口增大 3 条曲线总体变化趋势为先减小后增大。窗口长度为 3~4，混淆率在

最小值附近浮动。窗口小于 3 时，随着窗口增大混淆率明显减小。主要原因为：1) 窗口大小为 1 意味着计算当前结果可信度时没考虑前后动作，违背了 S-HMM 的初衷；2) 窗口为 2 意味着计算当前结果的可信度时参考了其相邻动作的识别结果，所以混淆率大幅降低；3) 窗口为 3~4 相当于计算当前结果的可信度时参考了若干个相邻识别结果，此时混淆率最低。

窗口大于 4 时，随窗口增大混淆率逐渐增大。主要原因为，窗口较大意味着计算当前结果的可信度时不仅参考了相邻识别结果，而且参考了与其距离较远的识别结果。但是，距离较远的 2 个样本之间的联系已经非常微弱。此时，计算其中一个结果的可信度时，参考另一个是没有意义的。所以随窗口增大，混淆率逐渐升高。

综上所述，S-HMM 中设定的滑动窗口太小会导致利用动作上下文信息不充分，太大会造成过多考虑上下文信息，2 种情况皆会导致混淆率升高。应用中窗口取 3 可达到最佳效果。

### 3.5 适应性分析

以上的实验数据来自真实场景。真实场景的变化会导致动作持续时间及动作间的转换概率发生变化，这 2 个参数的变化将直接影响 S-HMM 的性能。为了分析 S-HMM 的最坏情况，本小节对测试数据的动作序列进行了随机重组。重组过程中，每一类动作的持续样本数被设置为指定长度  $len$ ，且动作的转换随机指定。重组后得到一个新的动作序列。仿真过程中，通过改变动作持续样本数  $len$ ，可以使该序列模拟不同的应用场景。图 7 中给出了手机位于位置 6 时，随  $len$  的变化识别结果可信度混淆率的变化情况。




图 7 动作持续长度与混淆率的关系

因为基于分类器的可信度方法与样本上下文无关,所以  $len$  不影响该方法的混淆率,其值稳定在 0.15 左右。而 S-HMM 随  $len$  的增加,混淆率明显下降。当  $len$  取 2 或 3 时,S-HMM 的效果比使用权值差,主要原因如下。当动作的持续时间很短且动作之间的转换没有规律时,样本与其相邻样本之间的联系变弱。这使使用前样本的识别结果判断当前样本是否识别正确是没有意义的。动作持续样本数增大后,相邻样本间的关联变强,这使 S-HMM 的混淆率明显低于基于分类器的方法,且动作持续样本数越大,S-HMM 的效果越好。

但是,实际应用中 S-HMM 的混淆率高于基于分类器的方法是很少出现的,原因有 2 个:1) 原始数据划分窗口时,每个样本包含约 1 s 的原始数据<sup>[2]</sup>。动作持续样本数为 3 意味着人体每 3 s 变换一次动作,这在应用场景中是较少出现的;2) 本节的序列重组方法随机指定动作的转换。但在实际应用场景中,动作之间的转换有明显的规律。如上楼动作之后下楼的概率要远小于走路。规律的动作转换将会降低可信度的混淆率。

综上所述,虽然 S-HMM 在动作持续时间非常短的情况下效果不如基于分类器的方法,但是在动作持续长度大于 3 的实际应用场景中,S-HMM 的效果明显好于当前方法。另外,由于 S-HMM 计算得到的可信度与样本在特征空间中的分布无关,所以该方法更适用于手机位置自适应等一些特定领域。

#### 4 结束语

基于运动传感器的人体动作识别不仅需要实时识别人体动作,而且需要计算动作识别结果的可信度。本文提出了基于 HMM 的动作识别结果可信度计算方法 S-HMM。该方法首先使用识别结果序列更新 HMM 参数,然后使用 HMM 理论计算结果识别正确的概率,最后将该概率作为样本识别结果的可信度。与当前基于分类器的方法相比,S-HMM 将可信度的混淆率降低了 37% 左右。通过 3.5 节的分析可得,S-HMM 在动作转换频繁且无规律时表现较差。因此,未来的工作将着眼于动作转换频繁时可信度计算方法的改善。

#### 参考文献:

[1] HOSEINI S A, GLUHAKA, TAFAZOLLI R. A survey on smart-

- phone-based systems for opportunistic user context recognition[J]. ACM Computing Surveys (CSUR), 2013, 45(3): 1-27.
- [2] BULLING A, BLANKE U, SCHIELE B. A tutorial on human activity recognition using body-worn inertial sensors[J]. ACM Computing Surveys (CSUR), 2014, 46(3): 57-76.
- [3] CHIANG J H, YANG P C, TU H. Pattern analysis in daily physical activity data for personal health management[J]. Pervasive and Mobile Computing, 2014, 13(4): 13-25.
- [4] ZHOU B, LI Q, MAO Q, et al. Activity sequence-based indoor pedestrian localization using smartphones[J]. IEEE Transactions on Human-Machine Systems, 2015, 45(5): 562-574.
- [5] MARTÍN H, BERNARDOS A M, IGLESIAS J, et al. Activity logging using lightweight classification techniques in mobile devices[J]. Personal and Ubiquitous Computing, 2013, 17(4): 675-695.
- [6] SUAREZ I, JAHN A, ANDERSON C, et al. Improved activity recognition by using enriched acceleration data[C]//The 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing. ACM, c2015: 1011-1015.
- [7] REISS A, HENDEBY G, STRICKER D. A novel confidence-based multiclass boosting algorithm for mobile physical activity monitoring[J]. Personal and Ubiquitous Computing, 2015, 19(1): 105-121.
- [8] YOUNES R, MARTIN T L, JONES M. Activity classification at a higher level: what to do after the classifier does its best[C]//The 2015 ACM International Symposium on Wearable Computers. ACM, c2015: 83-86.
- [9] CHEN Y Q, ZHAO Z T, WANG S Q, et al. Extreme learning machine-based device displacement free activity recognition model[J]. Soft Computing, 2012, 16(9): 1617-1625.
- [10] DENG W Y, ZHENG Q H, WANG Z M. Cross-person activity recognition using reduced kernel extreme learning machine [J]. Neural Networks, 2014, 53(1): 1-7.
- [11] 赵中堂. 自适应行为识别中的迁移学习方法研究[D]. 北京: 中国科学院大学, 2013.
- ZHAO Z T. Transfer learning methods for adaptive activity recognition[D]. Beijing: University of Chinese Academy of Sciences, 2013.
- [12] QUINLAN J R. Induction of decision trees[J]. Machine Learning, 1986, 1(1): 81-106.
- [13] COVER T M, HART P E. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13(1): 21-27.
- [14] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [15] FREDERICK J. Statistical methods for speech recognition[M]. The United States: MIT Press, 1997.
- [16] 杨晓峰, 孙明明, 胡雪蕾, 等. 基于改进隐马尔可夫模型的网络攻击检测方法[J]. 通信学报, 2010, 31(3): 95-101.
- YANG X F, SUN M M, HU X L, et al. Improved HMM model based method for detecting cyber attacks[J]. Journal on Communications, 2010, 31(3): 95-101.
- [17] 黄飞跃, 徐光祐. 视角无关的动作识别[J]. 软件学报, 2008, 19(7): 1623-1634.
- HUANG F Y, XU G Y. Viewpoint independent action recognition[J]. Journal of Software, 2008, 19(7): 1623-1634.
- [18] AGGARWAL J K, RYOO M S. Human activity analysis: a review[J]. ACM Computing Surveys (CSUR), 2011, 43(3): 1-43.

- [19] KASTEREN T, NOULAS A, ENGLEBIENNE G, et al. Accurate activity recognition in a home setting[C]//The 10th International Conference on Ubiquitous Computing. Seoul, c2008: 1-9.
- [20] SHEHROZ S K, MICHELLE E K, JESSE H, et al. Towards the detection of unusual temporal events during activities using HMMs[C]//The 14th International Conference on Ubiquitous Computing. Seattle, c2012: 1075-1084.
- [21] FORKAN A R M, KHALIL I, TARI Z, et al. A context-aware approach for long-term behavioural change detection and abnormality prediction in ambient assisted living[J]. Pattern Recognition, 2015, 48(3): 628-641.
- [22] ZHONG M, WEN J, HU P, et al. Advancing Android activity recognition service with Markov smoother[C]//2015 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops). IEEE, c2015: 38-43.



张建忠 (1964-), 男, 河北石家庄人, 博士, 南开大学教授、博士生导师, 主要研究方向为移动计算、对等计算、网络安全。



徐敬东 (1965-), 女, 辽宁锦州人, 博士, 南开大学教授、博士生导师, 主要研究方向为移动计算、信息安全、网络管理。

#### 作者简介:



王昌海 (1987-), 男, 山东聊城人, 南开大学博士生, 主要研究方向为动作识别、移动情景感知、室内定位。



许昱玮 (1985-), 男, 安徽黄山人, 博士, 南开大学讲师、硕士生导师, 主要研究方向为移动计算、无线网络、车载自组织网络。