·人工智能及识别技术· 文章编号：1000-3428(2018)04-0262-06 文献标志码：A 中图分类号：TP391

基于区域分布概率密度估计的轨迹分类方法

曹卫权，李智翔，魏 强，褚衍杰

（盲信号处理重点实验室，成都 610041）

摘 要： 区域分布是运动目标的重要特征，可用于目标轨迹分类。已有分类方法往往假设轨迹片段呈矩形簇状或混合高斯状分布，限制了轨迹分类精度的提升。为此，提出一种基于核密度估计和最大似然判决的轨迹分类方法，消除已有分类方法对数据分布模型的先验假设，进而解决因模型不适配导致的轨迹分类准确率受限问题。实验结果表明，相较于最小描述长度划分、高斯混合模型等方法，该方法对参数不敏感，训练时间明显缩短，轨迹分类准确率提升 5%～15%。

关键词： 轨迹分类；最小描述长度；核密度估计；高斯核；最大似然

中文引用格式： 曹卫权，李智翔，魏 强，等. 基于区域分布概率密度估计的轨迹分类方法[J]. 计算机工程，2018，44(4)：262-267，286.

英文引用格式： CAO Weiquan，LI Zhixiang，WEI Qiang，et al. Trajectory Classification Method Based on Probability Density Estimation of Regional Distribution[J]. Computer Engineering，2018，44(4)：262-267，286.

Trajectory Classification Method Based on Probability Density Estimation of Regional Distribution

CAO Weiquan，LI Zhixiang，WEI Qiang，CHU Yanjie

（National Key Laboratory of Science and Technology on Blind Signal Processing，Chengdu 610041，China）

【Abstract】 Regional distribution is an important feature of moving target，which can be used for target trajectory classification. Previous methods assumed that segments of trajectories distribute as rectangles or Gaussian components，thus the accuracy of trajectory classification is significantly limited. To solve the problem，a novel method that takes use of kernel density estimation and maximum likelihood principle is proposed. It has no assumption on the data，so the problem of trajectory classification accuracy limited by model discomfort is solved. The experimental results show that compared with the existing Minimum Description Length（MDL） partition and Gaussian Mixture Model（GMM），the proposed method is insensitive to parameters，training time is shortened，and track classification accuracy is increased by 5%～15%.

【Key words】 trajectory classification；Minimum Description Length（MDL）；kernel density estimation；Gaussian kernel；maximum likelihood

DOI： 10.3969/j.issn.1000-3428.2018.04.042

0 概述

随着科技的进步，定位手段越来越多样，人们可以通过多种不同的途径获取轨迹数据，基于轨迹数据的目标属性识别也逐渐成为目标分析的重要手段。例如，可以基于运动轨迹识别出行交通方式[1]、基于视频监控中提取的运动轨迹识别被监控对象的行为模式[2]等。利用轨迹数据进行目标分类具有潜在信息量丰富、无需额外添加传感器、不易伪装篡改等优点。

在实际应用中，需根据轨迹数据的特点选择相应的分类算法。对于通过 GPS 等手段获取的位置数据，其定位误差小、采样率高，一般通过提取轨迹的局部差分显著特征来对其进行分类。例如，文献[1]针对手持设备采集的市区移动轨迹，计算其速度、加速度、转向率、停止率等显著特征，实现出行交通模式的识别；文献[3-4]针对 Auslan 手语数据提取轨迹的曲率、挠率等旋转不变量，实现手语词汇的识别；文献[5]考虑轨迹数据的尺度差异，提出利用曲率树结构来对手语轨

作者简介：曹卫权(1989—)，男，博士，主研方向为机器学习、数据挖掘；李智翔、魏 强，博士；褚衍杰，工程师、博士。

收稿日期：2017-02-14 修回日期：2017-04-18 E-mail：caoweiquan322@126.com

迹数据进行识别。

尽管上述方法具有极强的实用价值,但并不适用于一些具体的应用场景。如在 Starkey 项目中,研究者通过采集北美有蹄动物的迁徙数据来探索动物习性的变化[6],该数据由无线电遥测手段获取,定位误差和采样间隔较大,提取速度、曲率等元数据特征时会引入较大误差,导致分类结果极不可靠。此外,通过雷达扫描、Wifi 室内定位[7]、蜂窝定位、Flicker 照片位置数据[8]等手段获取的轨迹数据都具有类似的统计特点。对于这类数据,若不同类别的轨迹数据在空间上严重重叠,则一般认为其可分性不强;反之,若轨迹在空间中存在一定程度的分离现象,则可充分挖掘其位置相关特征。

文献[9-10]对二维轨迹段所在的二维空间进行划分,以最小描述长度(Minimum Description Length,MDL)为划分粒度的选取准则,提取仅包含一类轨迹的矩形"同质区域"作为特征。相较于轨迹模式特征[1]方法,该方法不仅提高了轨迹的分类准确率,还提升了分类器的训练效率。但是,该方法假设显著区域呈近似矩形状分布,这一假设在实际中并不一定适用。此外,为减小最佳划分的搜索复杂度,该方法采用向 x、y 轴分别投影的方式交替选取各坐标轴的划分点,这一策略在轨迹簇分布区域的划分时具有局限性。为解决该局限性,文献[11]提出采用空间区域合并的策略提取同质区域,然而该方法并未消除矩形区域形状的限制,仍有较强的局限性。此外,文献[12-13]提出利用高斯混合模型(Gaussian Mixture Model,GMM)来拟合轨迹段在空间中的分布,该方法消除了区域划分法的缺陷,且将应用范围扩展至三维甚至更高维度的轨迹数据分类问题。但是,GMM 方法的缺陷在于其引入了高斯分量个数 K,不同的 K 值会影响分类结果:较小的 K 值不足以描述复杂的轨迹区域分布,较大的 K 值时可能因为模型过于复杂而导致训练失败。

针对上述问题,本文提出基于核函数密度估计[14-17]的方法获取轨迹片段在空间中的概率分布,并结合最大似然准则,实现轨迹数据的可靠分类。该方法不对轨迹的分布区域形状做任何假设,且无需引入额外的参变量。

1　基于核密度估计的轨迹分类方法

1.1　算法流程

基于核密度估计的轨迹分类方法流程如图 1 所示。

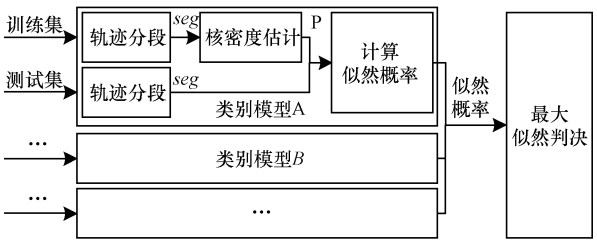


图 1　基于核密度估计的轨迹分类方法流程

该算法的具体流程如下:

1)基于 DOTS 算法[18]将每条轨迹划分为轨迹段。

2)基于每条轨迹段的中心点估计轨迹片段在二维空间中的概率密度分布。

3)借助已知的概率密度计算轨迹属于任一类别的似然概率,最后依据最大似然准则进行分类。

1.2　基于最小误差准则的轨迹分段

轨迹数据是典型的时间序列数据,具有不定长的数据特点,各轨迹点的位置分别包含经纬度和时间信息,如式(1)所示。

$$T=\{p_i=(lon_i,lat_i,t_i)\mid i=1,2,\cdots,N\} \tag{1}$$

其中,lon 表示经度,lat 表示纬度,t 表示时间。

通过核密度估计的方式得出各类轨迹在空间中的分布情况时,直接以轨迹 T 为元素进行密度估计显然不合理,本文借鉴文献[10]的思路,将每条轨迹切分成小片段,以这些片段为基础粒度,估计轨迹的区域分布情况。

文献[18]提出一种基于最优准则的轨迹数据分段方法,以增量的方式构建无回路有向图数据结构,通过在该图中动态搜索最短路径来获得原始轨迹的最优分段结果,如图 2 所示。该分段方法具有同等分段粒度下误差最小的优点。

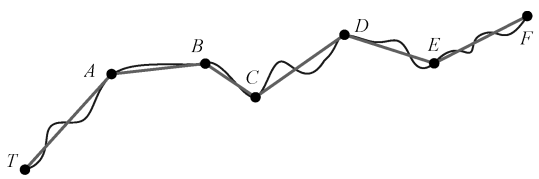


图 2　轨迹分段示意图

分段后,每条轨迹可用一系列轨迹段构成的有序集合表示,即:

$$T=\{seg_i\mid i=1,2,\cdots,M\} \tag{2}$$

在下文中,用 $\boldsymbol{x}_i$ 表示轨迹段 seg_i 的中点坐标。

1.3　自适应核密度估计

如前文所述,区域划分法[10]额外引入了轨迹片段呈矩形状聚类成簇的约束,与许多实际应用场景不符,限制了其分类准确率的提升。本文提出利用自适应核密度估计的方法来拟合各类别轨迹片段在

二维空间中的分布情况,其描述能力比矩形框更强。

核密度估计的计算方法如式(3)所示。

$$\hat{p}_h(x) = \frac{1}{N}\sum_{i=1}^{N} K_h(x - \boldsymbol{x}_i) = \frac{1}{Nh^D}\sum_{i=1}^{N} K\left(\frac{x - \boldsymbol{x}_i}{h}\right)$$

$$\text{s.t.} \int K_h(x)\,\mathrm{d}x = 1 \tag{3}$$

其中,样本 $\boldsymbol{x}_i$ 是各轨迹片段的中点坐标,为二维或三维向量,D 是样本 $\boldsymbol{x}_i$ 的维度,h 是可调参数,N 是样本数量,x 是样本空间内任意值,$K(x)$是核函数,为确保 $\hat{p}_h$ 满足概率密度函数的基本性质,要求 K_h 的无穷积分恒为 1。

根据需求的不同,核函数的类型有均值核、三角核、双权重核、Epanechnikov 核、Gaussian 核等。由于 Gaussian 函数具有诸多良好的数学性质,因此其应用较广[14-15]。

式(3)中存在被称为带宽的可调参数 h,给定任意一种核函数,结合 h 可以构成一系列核函数族,即:

$$K_h(x - \boldsymbol{x}_i) = \frac{1}{h^D}K_1\left(\frac{x - \boldsymbol{x}_i}{h}\right) \tag{4}$$

不难证明,对任意 $h>0$,K_h 均满足式(4)所示的约束条件,其为合法的核函数。与直方图统计类似,核密度估计的结果也受带宽取值影响,如图 3 所示。

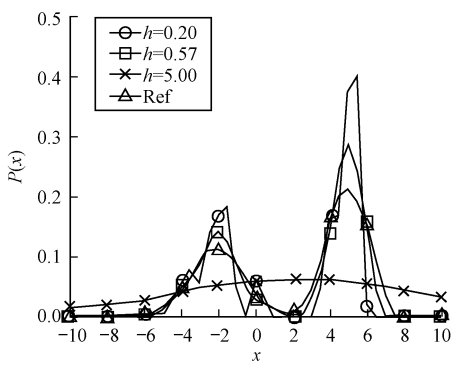


图 3 带宽 h 对一维核密度估计结果的影响

对于给定的参考概率分布(图中“Ref”曲线)随机生成数据样本,然后分别以带宽 h 取值 0.20、0.57、5.00来估计样本的概率密度,由图 3 可以看出,得出的结果存在明显差异。一般来说,h 取值越小,密度估计的偏差就更接近0。若数据样本无限充足,一般认为 h 取值越小越好,但实际应用中数据样本有限,需要在概率密度的偏差和分布的复杂程度之间作出平衡。h 取值过小会导致估计结果包含太多峰谷,推广性不佳,统计上称之为欠平滑;反之,h 取值过大,则不足以发掘数据样本中的局部分布差异,称之为过平滑。

一般采用式(5)所示的指标来衡量带宽取值的优劣。

$$MISE\{p(\cdot)\}(h) = E_p\left[\int [\hat{p}_h(x) - p(x)]^2\,\mathrm{d}x\right] \tag{5}$$

对于任意概率分布 $p(x)$,指标 MISE 描述了核密度估计结果$\hat{p}_h(x)$与真实分布差异的期望,其是 h 的函数。其中,期望 E_p 对应的随机变量为给定概率分布 $p(x)$下生成的 M 个随机样本$\{x_1,x_2,\cdots,x_M\}$。

MISE 与 $p(x)$和 h 间的函数关系复杂,不便求极值。在概率分布 $p(x)$二阶可导的假设下,可用式(6)所示的渐进式误差度量替代 MISE,两者仅相差无穷小项 $o(1/Nh+h^4)$[14]。

$$AMISE(h) = \frac{R(K)}{Nh} + \frac{1}{4}m_2(K)^2h^4R(p'')$$

$$\text{s.t.} \lim_{N\to\infty} h = 0,\ \lim_{N\to\infty} Nh = \infty \tag{6}$$

对 AMISE 求导得式(7)所示的极值点,即为最佳带宽。

$$h_{\text{AMISE}} = \frac{R(K)^{1/5}}{m_2(K)^{2/5}R(p'')^{1/5}N^{1/5}} \tag{7}$$

在实际应用中,若对带宽精度要求不高,可利用 Silverman 大拇指规则[14]简易求解最优带宽,如式(8)所示,其中仅需计算样本的分布标准差 $\hat{\sigma}$ 即可。

$$h_{\text{opt}} \approx 1.06\hat{\sigma}N^{-1/5} \tag{8}$$

尽管采用插入带宽选择器[15]、交叉验证带宽选择器等求解得到的最优带宽更准确,但本文第 3 节的实验表明,虽然密度估计的准确性与带宽密切相关,但基于密度估计轨迹分类方法的正确率却对带宽不敏感,只要选择相对较合理的 h 值即可,不必过于精确。基于上述讨论,算法 1 给出了核密度估计部分参考实现,其中 P 为查表形式的概率密度函数,$IDX(P)$表示函数表的下标集。

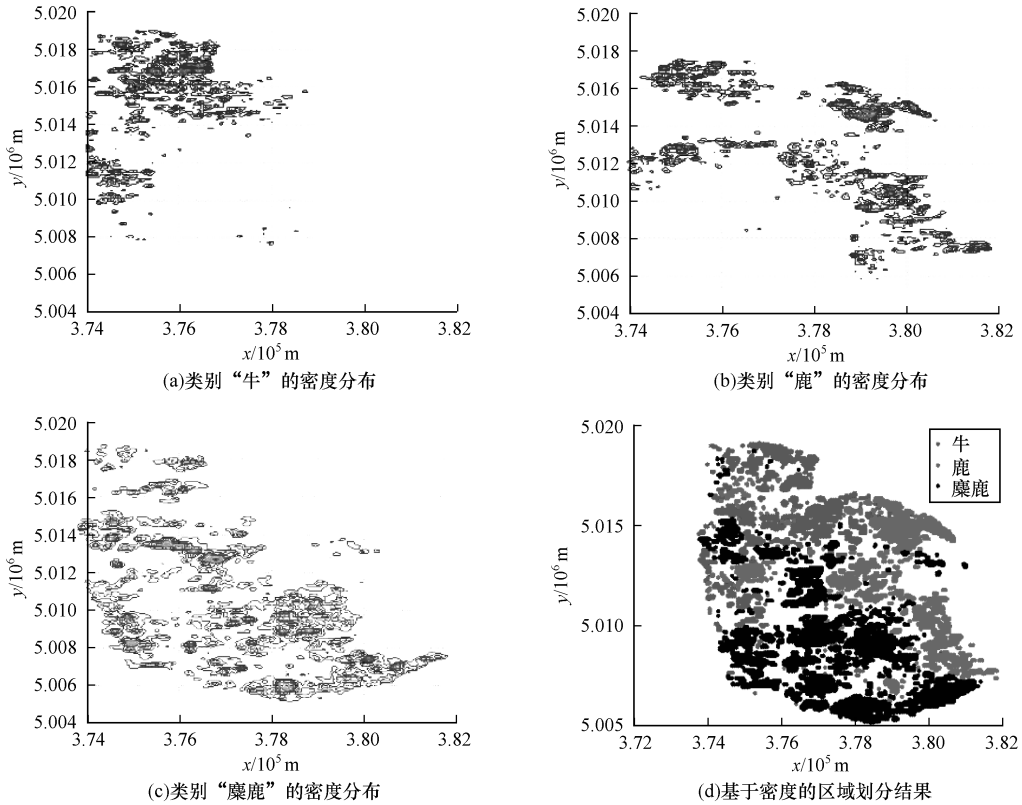
算法 1 自适应核密度估计

输入 属于同一类别 c 的轨迹段集合 $X=\{x_1,x_2,\cdots,x_n\}$

输出 概率密度函数 P

```
1. σ̂ = √(E²x − Ex²)
2. h = 1.06σ̂n^(−1/5)
3. P = 0
4. FOR x_i ∈ X DO
5.    FOR x_0 IN IDX(P) DO
6.       P(x_0) = P(x_0) + K_h(x_0 − x_i)/n
7.    END FOR
8. END FOR
9. RETURN P
```

以 Starkey 动物迁徙轨迹数据[6]为例,轨迹段在二维空间的概率密度估计如图 4 所示,其中图 4(a)、图 4(b)、图 4(c)分别表示牛、鹿、麋鹿 3 类动物的密度分布,色阶越暖表示概率密度越大,反之,则概率密度越小。



(a)类别“牛”的密度分布　(b)类别“鹿”的密度分布

(c)类别“麋鹿”的密度分布　(d)基于密度的区域划分结果

图 4　Starkey 数据集的区域分布密度估计结果

根据概率密度的比值,可以将 3 类轨迹数据的显著分布区域按式(9)进行划分,如图 4(d)所示。式(9)仅以类别“牛”为例说明,其他类别的数据可以类比定义。

$$l_x = \text{cattle},\ \text{i. f. f.}$$
$$p_{\text{cattle}}(x) > \alpha p_{\text{deer}}(x),\ p_{\text{cattle}}(x) > \alpha p_{\text{elk}}(x)$$
$$\alpha > 1 \tag{9}$$

从图 4(d)可以看出,基于密度估计的类别划分方法未对数据的分布形状做任何强假设,分界面更加灵活,分类效果较好。

1.4　基于最大似然度的轨迹分类

尽管可以利用式(9)所示的显著区域进行轨迹分类,但这一方法引入了参数 α,增加了使用过程中的算法调参步骤。针对这一问题,本文在轨迹段独立同分布的假设下,计算轨迹 T 属于类别 c 的似然概率,以似然概率作为分类依据。

$$P(l_T = c \mid T) = \prod_{seg_i \in T} \hat{p}_{h,c}(seg_i) \tag{10}$$

独立同分布假设相较于 Markov 等链式模型[19]的优点在于,其概率模型更简单,对数据样本量的要求更低,应用场景更广泛。

考虑到式(10)连乘过程可能引起浮点数数值溢出问题,可采用式(11)所示的对数累加形式计算轨迹的对数似然概率,其与式(10)等效。

$$\log_a P(c \mid T) = \sum_{seg_i \in T} \log_a \hat{p}_{h,c}(seg_i) \tag{11}$$

注意到式(10)与式(11)易受累加式中单个元素的影响。例如,假设已知轨迹 T 的标签为 c,对于 T 的任一片段 seg_i,若该片段定位偏差较大,使得 $\hat{p}_{h,c}(seg_i) \to 0$,则根据式(11),$\log_a P(c \mid T) \to -\infty$,这将直接导致错误分类。解决这一问题有多种思路:一方面可以在式(10)中排除零值项;另一方面,可以借鉴文献[10]的思路,仅累计式(9)定义的显著区域中的概率。本文提出一种更简洁的解决方案,如式(12)所示。

$$\log_a P'(l_T = c \mid T) = \sum_{s_i \in T} \log_a (\hat{p}_{h,c}(s_i) + \varepsilon) \tag{12}$$

其中,$\varepsilon > 0$ 为一较小的正实数,对概率密度提供零值保护。

仍考虑上述轨迹段 seg_i,参照式(12),则似然概率偏差为 $\Delta \log_a P'(l_T = c \mid T) \approx \log_a P'(\varepsilon)$,$seg_i$ 定位偏差对似然概率的影响大大减小。另一方面,若 seg_i 为定位准确的片段,则参数 ε 引入的误差如式(13)所示。

$$\Delta_\varepsilon = \log_a (\hat{p}_{h,c}(s_i) + \varepsilon) - \log_a \hat{p}_{h,c}(s_i) = \log_a \left(1 + \frac{\varepsilon}{\hat{p}_{h,c}(s_i)}\right) \approx \frac{\varepsilon}{\hat{p}_{h,c}(s_i)} \tag{13}$$

当 $\varepsilon << \hat{p}_{h,c}(s_i)$ 时,Δ_ε 可以忽略不计。

通过第 3 节的真实数据实验,发现这一微小改进能够令学习器的分类正确率提升 5% 左右,效果显著。

最后,以最大似然概率为判别准则,计算轨迹的类别标签,如式(14)所示。

$$l_T^* = \text{argmax}_c \log_a P'(l_T = c \mid T) \tag{14}$$

上述工作流程可归纳为如算法 2 所示的伪代码。其中,$seg(T)$表示对轨迹 T 按照 DOTS 算法进行划分得到的轨迹段集合,函数 $NN(A,b)$用于在集合 A 中寻找点 b 的最近邻。

算法 2 最大似然判别

输入 类别集合 $C=\{c_1,c_2,\cdots,c_m\}$,各类别轨迹段空间分布概率估计 P_c,待分类轨迹 T

```
1. X = seg(T)
2. FOR c ∈ C DO
3.    FOR x_i ∈ X DO
4.       x = NN(IDX(P_c), x_i)
5.       Pr_c(T) = Pr_c(T) + log_a[P_c(x) + ε]
6.    END FOR
7. END FOR
8. RETURN argmax_c Pr_c(T)
```

2 算法分析

2.1 时间复杂度

训练环节是机器学习任务总复杂度的主要组成部分。在轨迹分段阶段,DOTS 算法的复杂度为 $O(N_0)$[18],其中 N_0 为原始轨迹数据集中轨迹点的总量,设分段压缩比为 r,生成的轨迹段数量约为 N_0/r。考虑到密度估计算法的可操作性,式(3)的输出 $\hat{p}_h(x)$一般并不是连续函数,而是以函数表的离散形式给出。由于已有的核函数 $K(x)$均不是重尾分布,因此对于每个数据样本 $\boldsymbol{x}_i$,$K(x-\boldsymbol{x}_i)$对 $\hat{p}_h(x)$的影响范围有限。函数表一般取矩形格网的形式,格网规模 G 越大,则训练复杂度越高。观察式(3)可知,核密度估计与样本点数量 N_0/r 成正比。综上所述,该机器学习算法训练过程的复杂度为 $O(N_0+N_0G/r)$。若没有轨迹分段过程,则算法复杂度为 $O(N_0G)$,轨迹分段过程不仅保留了轨迹的主要信息,同时也降低了算法复杂度。

在似然概率计算环节,$\hat{p}_{h,c}(seg_i)$以查表法得出,复杂度为 $O(1)$,因此,对于轨迹段数量为 M 的单条轨迹,其分类复杂度为 $O(M)$。

2.2 适用范围

综合前文的原理分析,将本文轨迹分类方法的适用范围汇总如下:

1)轨迹数据的类别标签与区域分布有一定相关性。

2)轨迹数据受采集手段限制,采样率较低、定位精度较差,不利于采用速度、加速度、运动模式等特征进行分类。

3 实验结果与分析

3.1 实验数据

本文以 Starkey 动物迁徙数据[6]和海洋船舶 AIS 数据[20]为例,测试各分类方法在轨迹数据分类方面的性能。2 个数据集的统计特征如表 1 所示,其中 Starkey 轨迹按照动物物种分为牛、鹿和麋鹿,船舶轨迹数据按照目标所属国家分为挪威、英国、法国。

表 1 实验数据

数据集名称	轨迹数量	点数量	类别标签	坐标单位
Starkey	100	19 474	牛,鹿,麋鹿	m
AIS	205	1 367 126	挪威,英,法	经纬度

在本文实验中,如无特别说明,使用的默认参数为 $h_{\text{opt}}\approx 1.06\hat{\sigma}N^{-1/5}$,$G=256$,$\varepsilon=10^{-5}$。

3.2 分类准确率分析

为对比各算法的分类准确率,采用 5 折交叉验证的方式,每次从各数据集中随机抽取 80% 的轨迹进行训练,剩余 20% 的轨迹用于测试。为保证实验结果统计可信,每项实验均重复进行 50 次。各算法的分类错误率如表 2 所示。

表 2 各轨迹分类算法错误率比较 %

分类算法	Starkey	AIS
MDL 区域划分法	22.70	45.27
区域合并法	21.43	48.16
GMM 方法(零值保护)	17.20	36.13
本文方法(无零值保护)	17.60	39.50
本文方法(零值保护)	12.90	30.16

由表 2 可以看出,本文方法在 2 类数据集下的准确率均高于对比方法[10-11,13]。值得注意的是,式(12)引入的零值保护措施显著提升了分类性能,在 Starkey 数据集下准确性提升 4.7%,在 AIS 数据集下准确性提升高达 9.34%,其原理已在 1.4 节讨论。另外,将本文的零值保护方法应用于 GMM 模型,分类准确率相比于区域划分法[10]、合并法[11]也有明显改进,但仍比本文方法低约 5%。

本文分类方法共引入了 2 项参数,带宽 h 与网格规模 G。以 Starkey 数据为例测试分类错误率与 2 项参数的关系,如图 5、图 6 所示,发现分类结果对 2 项参数均不敏感。注意到,只要 h 设置合理,则分类错误率基本稳定在 15% 左右。参照 Silverman 大拇指规则,合理的 h 应该在样本标准差 $\hat{\sigma}$ 附近。实验结果表明,h 在较大的范围内,如 $0.01\hat{\sigma}\sim 100\hat{\sigma}$,均不影响分类结果。当 h 设置严重不合理时($h>10^4\hat{\sigma}$),分类错误率将骤升。

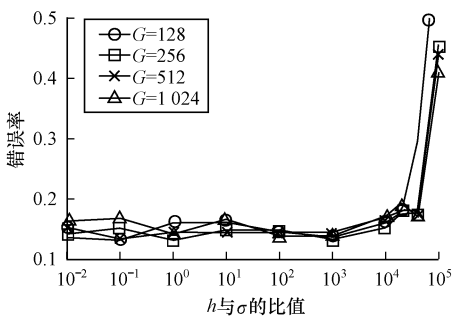


图 5 分类错误率与带宽的关系

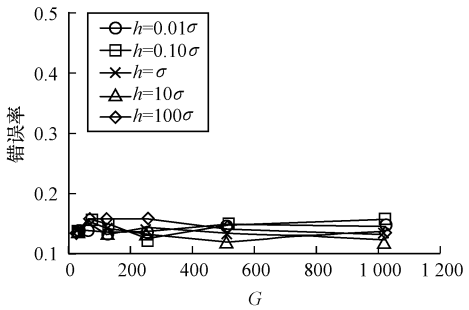


图 6　分类错误率与网格规模的关系

3.3　分类效率分析

本文算法的另一个突出优势在于其训练时间较短。本文借助积分图等数据结构高效地实现了 MDL 区域划分算法[10],在 2 项数据集上进行实验,结果如表 3 所示。

表 3　各轨迹分类算法训练效率比较　　s

分类算法	Starkey	AIS
MDL 区域划分法	3.77	2.75
区域合并法	4.63	3.52
GMM 方法	1.27	2.30
本文方法	0.36	0.28

从表 5 可知,本文方法训练时间仅约为对比算法的 10% 。

实验还分析了训练时间与带宽 h 和网格规模 G 的关系,结果如图 7、图 8 所示。

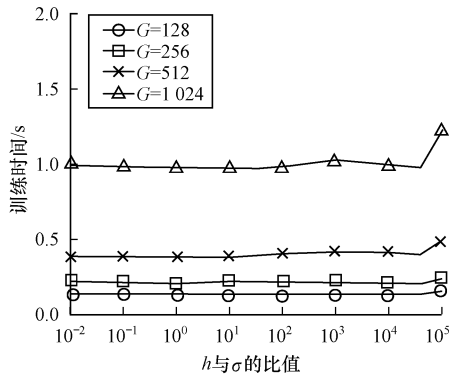


图 7　训练时间与带宽的关系

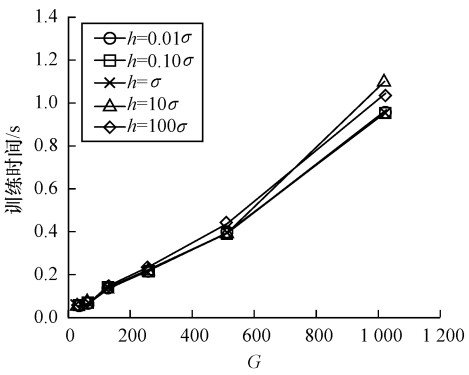


图 8　训练时间与网格规模的关系

从图 7、图 8 可以看出,训练时间与 h 不相关,而与 G 呈线性关系,这也证实了前文对复杂度的理论分析结果。

本节的实验结果可以为算法的参数选择提供指导。随着网格规模的增加,分类准确性变化不大,但训练时间呈线性增长,因此,G 参数宜相对较小,一般采用 $G = 256$ 作为默认设置。此外,h 不影响训练时间,但需设置在合理的范围内,一般取 $h \in (0.01\hat{\sigma}, 100\hat{\sigma})$时,分类效果较好。

4　结束语

区域分布特征是轨迹数据分类的重要支撑,针对 MDL 区域划分法、混合高斯模型等对数据分布先验假设过强的问题,本文提出一种不依赖数据模型的轨迹分类方法。首先利用核密度估计获取各类别数据在空间中的概率密度分布,然后采用最大似然判决实现目标分类。该方法对带宽、网格规模等参数不敏感,训练时间较短,且分类准确率较高。下一步将在区域特征与运动模式、加速度等其他特征的融合利用方面开展研究。

参考文献

[1] ZHENG Y, LIU L, WANG L, et al. Learning transportation mode from raw GPS data for geographic applications on the Web[C]//Proceedings of the 17th International Conference on World Wide Web. New York, USA:ACM Press,2008:247-256.

[2] PUSIOL G, BREMOND F, THONNAT M. Trajectory based activity discovery[C]//Proceedings of the 7th IEEE International Conference on Advanced Video and Signal Based Surveillance. Washington D. C., USA: IEEE Press,2010:270-277.

[3] KADOUS M W. Temporal classification: extending the classification paradigm to multivariate time series[D]. New South Wales, Australia: University of New South Wales,2002.

[4] YANG Jianyu, LI Y F, WANG Keyi, et al. Mixed signature: an invariant descriptor for 3D motion trajectory perception and recognition[J]. Mathematical Problems in Engineering,2012(3):488-516.

[5] NIERHOFF T, HIRCHE S. Trajectory classification in n dimensions using subspace projection[C]//Proceedings of 2012 IEEE International Conference on Intelligent Robots and Systems. Washington D. C., USA: IEEE Press,2012: 1318-1323.

[6] ROWLAND M M, COE P K, STUSSY R J, et al. The starkey habitat database for ungulate research: construction, documentation, and use[J]. Forest Service General Technical Report,1998(5):103-112.

[7] WANG Yan, LIU Jian, CHEN Yingying, et al. E-eyes: device-free location-oriented activity identification using fine-grained WiFi signatures[C]//Proceedings of the 20th Annual International Conference on Mobile Computing and Networking. New York, USA: ACM Press,2014:617-628.

(下转第 286 页)