

# 基于智能手机的车辆行为实时判别与渐进矫正方法研究

范菁 吴青青 叶阳 董天阳

(浙江工业大学计算机科学与技术学院 杭州 310023)

**摘要** 目前基于智能手机的车辆行为识别算法存在着鲁棒性较差、识别率较低、无法应用于实时行驶判断等问题。针对上述问题,提出了基于智能手机的车辆行为实时判别与渐进矫正方法,以提高车辆行为识别的准确率和实时性。该方法利用车辆行为发生时存在的渐进变化数据来进行车辆行为的识别与渐进矫正分类,并通过采集过程数据作为分类器训练样本,提高支持向量机(SVM)分类器的车辆行为识别和预测能力。同时,针对传统滑动窗口检测的局限性,该方法采用了端点检测算法,从而能快速地从车辆行驶数据中截取并识别行为轨迹信息,以减少车辆行为的误判。实验结果表明,基于时间分段矫正的行为识别算法能够有效地对车辆行为进行预测,并最终达到较高的识别率,证明了该方法的有效性。

**关键词** 车辆行为识别, SVM, 实时判别

**中图分类号** TP391.4      **文献标识码** A      **DOI** 10.11896/j.issn.1002-137X.2017.03.059

## Real-time Determination and Progressive Correction of Vehicle Behavior on Smartphones

FAN Jing WU Qing-qing YE Yang DONG Tian-yang

(School of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)

**Abstract** Up to now, the relevant research has some drawbacks: poor robustness, low accuracy rate and non-real time. To solve these problems, a vehicle behavior recognition algorithm of real-time determination and progressive correction on smartphone was proposed. This algorithm classifies vehicle behavior by the data generated during driving process, and uses the collected data as training samples to improve recognition and prediction capability of SVM. For the limitations of traditional sliding window, the endpoint detection algorithm is used to quickly extract useful information from the complete vehicle behavior, which reduces misjudgment simultaneously. The experimental results show that corrective algorithm on time-based segmentation can effectively predict the vehicle behavior, and ultimately achieve high recognition rate, which demonstrates the effectiveness of this method.

**Keywords** Vehicle behavior recognition, SVM, Real-time determination

## 1 引言

随着车联网研究的不断推进,车辆行为识别技术作为智能交通领域中场景理解的重要内容,成为车辆检测和跟踪之外的又一研究热点。车辆行为识别主要通过学习运动车辆的行为模式,对车辆行驶轨迹或速度行为进行理解与分析。

目前,车辆行为识别的方法从监控设备来说主要分为3类。第一类以交通视频监控为代表,通过外部可视化的轨迹识别与模式聚类算法判断车辆的行为<sup>[1-2]</sup>。这种方式易受天气、光照强度、障碍或其他环境因素的影响,且在视频处理中专用摄像头的覆盖范围有限,成本高,存在一定的局限性。第二类以车载传感器为基础,结合油门、刹车、方向盘等硬件设备对车辆行为进行监控识别。由于车载传感器的精确度较高,因此这类方式能够获得较为精准的识别率。但同时因为车载传感器专业性强,价格高昂,此类车辆行为识别技术的应

用普及面受到限制。第三类则得益于智能手机自带的传感器。由于手机软硬件性能的不不断提升,能够利用智能手机自带的传感器获取车辆轨迹、加速度、旋转角度等数据。这种方式相较于其他两类方法,拥有抗外界干扰能力强、携带方便、价格低廉、获取数据方式自由等优点。这为本文基于智能手机的车辆行为研究提供了基础。

基于智能手机的车辆行为研究中,起初学者们使用的是单一的传感器。如 Kamran S 等<sup>[3]</sup>使用全球定位系统(Global Positioning System, GPS)进行异常车辆行为的检测,通过预先定义异常路段,实现基于先验规则的车辆行为识别。Ly M V 等<sup>[4]</sup>提出了利用惯性传感器对刹车和转弯加以区分的方法,但考虑到在室内或者其他复杂环境下 GPS 信号存在的偏差甚至丢失现象,学者们开始使用 GPS、加速度等传感器数据融合的方式来丰富系统的输入参数,提高判别准确率。Reddy S 等<sup>[5]</sup>通过实验的比较证明了单一的传感器用于行为

到稿日期:2016-02-29 返修日期:2016-05-30 本文受浙江省重大科技专项重大工业项目(2013C01112)资助。

范菁(1969—),女,博士,教授,主要研究方向为虚拟现实和服务计算;吴青青(1991—),女,硕士生,主要研究方向为机器学习、图像处理等;叶阳(1980—),男,实验师,主要研究方向为虚拟现实, E-mail: yeyang80@zjut.edu.cn;董天阳(1977—),男,博士,副教授,主要研究方向为计算机图形学、虚拟现实, E-mail: dty@zjut.edu.cn。

识别的效果并不理想,准确率会比传感器融合的方式下降 10%~20%。Feng T 等<sup>[6]</sup>通过单独 GPS、单独加速度传感器以及 GPS 与加速度传感器融合的 3 种方式分别利用贝叶斯信念网络模型以交通方式进行分类。结果显示,由于 GPS 信号的丢失,使用加速度传感器数据的准确率是 88.8%,高于单独 GPS 的准确率 78.4%;而 GPS 与加速度传感器融合的准确率最高,识别率为 91.7%。Johnson D A 等<sup>[7]</sup>设计并实现了 MIROAD 系统,其利用 GPS、加速度、陀螺仪、磁力计以及摄像头,采用动态时间规整(Dynamic Time Warping, DTW)分类算法对车辆轨迹进行分类,识别率达到了 91%。但其算法在实时性方面存在着明显缺陷,需要将待识别数据与每一种标准行为进行匹配,具有较高的计算时间复杂度。王相海等<sup>[8]</sup>提出了一种基于隐马尔科夫模型(Hidden Markov Model, HMM)的车辆行为实时判别方法,拥有较高的正确率和查全率。但它的实时性体现在对轨迹的分段匹配,使用的是固定数目的路径节点,在处理长短不一的车辆行为数据上其识别率会有一定的负面影响。Hao J Y 等<sup>[9]</sup>使用车辆行驶后形成的完整轨迹作为模式识别的对象,属于静态轨迹识别,因此也无法满足实时性需求。

总而言之,现有的基于智能手机的车辆行为识别方法中,一部分方法缺少车辆轨迹的去噪处理,车辆轨迹跟踪的鲁棒性较差;而另一部分方法虽然通过数据的预处理改善了车辆的行为识别准确率,但是从整体来看,这些方法大多是非实时性的,即通过记录车辆行为,在形成完整的轨迹后再对该时间段内的行为数据进行模式判别。这种方式可以认为是对车辆最终状态的识别,无法满足智能交通中车辆行为实时判别和预测的需求。另外,现有的方法一般利用传统的滑动窗口来统一车辆行为数据的长度。窗口的大小通常由人为经验数据确定,容易受主观因素的影响,对场景适应性较差。

针对以上问题,本文提出了基于智能手机的车辆行为实时判别与渐进矫正方法,以提高车辆行为识别的准确性和实时性。该方法的主要思想是通过端点检测算法自动计算车辆行为的起止点,克服滑动窗口主观性强的缺点。同时在算法的训练阶段对样本进行分段训练,达到实时矫正并预测的目的。该方法主要包含 4 个步骤:

1)对车辆行为数据进行预处理。通过去除不完整轨迹序列、轨迹重构和最小二乘法线性拟合方法恢复轨迹,并采用速度计算模型来确定车辆的运行速度,以及通过小波变换对传感器数据实现去噪。

2)利用方向角划分方法对轨迹进行编码,通过车辆行驶所产生的方向信息来描述车辆轨迹的几何形状,同时去除与具体位置点的相关性;之后对传感器数据进行基于时域和频域上的分析,并利用主成分分析法(Principal Component Analysis, PCA)对特征进行降维,加快算法的运行速度。

3)在算法的学习阶段对采集的数据利用支持向量机(Support Vector Machine, SVM)进行分段样本训练,充分学习行为特征。

4)在识别阶段利用端点检测算法检测车辆行为的起止点,并对该行为段内的数据进行充分分析,最终进行分类识别。

实验结果显示,本文算法能够达到较高的识别率,同时在

行为变化的过程中能够对当前行为进行实时判别和预测。

## 2 基于智能手机的数据采集与模型定义

在介绍本文的识别方法之前,首先对本文使用的数据采集参数和相关模型定义等信息做出说明。

**定义 1(数据收集模型)** 在任意离散时间  $t$ ,系统可以进行传感器数据的采集,获得 GPS 数据  $P$ 、加速度传感器数据  $A$ 、磁力计数据  $M$ 、陀螺仪数据  $G$ 。因此,一次采样的数据可以用一个五元组表示,即  $\langle t, P, A, M, G \rangle$ 。其中,  $t$  为时间戳, GPS 数据包括经度、纬度以及速度的具体信息,加速度、磁力计、陀螺仪的数据均有 3 个量,分别表示在 X 轴、Y 轴、Z 轴上的分量。

**定义 2(速度计算模型)** 假设车辆在某一时刻  $t_1$  位于位置点  $A$ ,经过  $\Delta t$  时间段后于时刻  $t_2$  达到位置点  $B$ 。要计算其移动过程中的平均速度,则可以通过地球模型进行几何计算得出。




图 1 地球模型

如图 1 所示,假设地球是半径为  $R$  的球形,点  $A$  投影在赤道平面上的点为点  $C$ ,因此可得:

$$\begin{cases} AC=ED=R * \sin LatA \\ OC=R * \cos LatA \\ BD=R * \sin LatB \\ OD=R * \cos LatB \\ BE=R * (\sin LatB - \sin LatA) \end{cases}$$

之后根据三角函数可以获得点  $A$  与点  $B$  两点之间的距离为:

$$D=R * (\cos^2 LatA + \cos^2 LatB - 2 * |\cos LatA| * |\cos LatB| * \cos(LonA - LonB))$$

其中,  $LonA, LatA$  分别代表的  $A$  点的经、纬度,  $LonB, LatB$  分别代表  $B$  点的经、纬度。

最终,该时段内的平均速度可表示为  $\bar{v}=D/\Delta t$ 。

**定义 3(轨迹编码模型)** 规定一个坐标系:以经度为横坐标,纬度为纵坐标。用相邻轨迹点所产生的方向角作为描述车辆行为的特征参数,表示当前时刻车辆的位置是落在其前一时刻的哪个象限中,即  $(x_{i+1}, y_{i+1})$  相对于  $(x_i, y_i)$  的位置。按逆时针方向每隔  $\pi/4$  确定一个方向,则可以确定 8 个

方向。之后利用8-方向角进行相应的编码,每一个方向区域均有一个码字相对应,具体映射关系如图2所示<sup>[8]</sup>。





图2 方向角划分



(a)数据收集 App



(b)手机放置方式

图3

手机传感器由于操作系统的不同,可供选择的采样范围也有差异。不同手机的传感器采样频率不同,GPS频率一般为1Hz,其他传感器一般为50~300Hz。以 Samsung Galaxy S4手机为例,GPS的最大采样频率是1Hz,加速度传感器、陀螺仪以及电子罗盘传感器的采样频率均为100Hz。而 new HTC ONE手机加速度传感器的采样频率是60Hz,陀螺仪和电子罗盘传感器的采样频率是100Hz。因此,为了减小不同采样频率对本实验的影响,本文实验系统中,GPS采样频率规定为1Hz,其他传感器采用的采样频率为50Hz。在手机收集数据之前,需要专门开发一款用于收集传感器数据的手机应用(见图3(a))。在实验数据的收集过程中,为了简化模型,直接将手机用车载支架进行固定(见图3(b)),以防止因手机移动或滑落而造成的噪声影响。事实上,若手机的放置

方向与本文有差异,也可通过坐标系转换方式将数据还原,增强实际应用性。

### 3 基于时间分段矫正的车辆行为识别与渐进矫正技术

车辆行为识别实质上是一个机器学习和模式识别的过程。本文利用智能手机内设的全球定位系统、加速度传感器、陀螺仪和磁力计,提出一种基于支持向量机的车辆行为实时判断方法。本文的车辆行为识别算法如图4所示,主要过程包括以下步骤:

#### (1)数据预处理

通过阈值判定方式去除不完整轨迹,利用路径重构算法恢复车辆行驶轨迹,使用最小二乘法对车辆轨迹进行线性拟合,去除异常点,保证轨迹序列的有效性;同时利用小波去噪算法对传感器数据进行滤波处理。

#### (2)特征提取

利用基于方向角区间划分方法对车辆的运行轨迹进行编码,并对去噪后的传感器数据进行基于时域和频域的特征提取,之后利用PCA进行降维并分析特征的相对重要性,加快算法的处理速度,以保证系统的实时性。

#### (3)分类训练

区别于一般方法,本文提出的算法在训练过程中对训练样本进行基于时间的分段。SVM使用分段结果的数据特征作为输入参数,以此来模拟车辆运动过程中行为数据逐步完善的过程。使用这种方式,SVM可以更好地适应不完整的传感器数据,提高行为识别的鲁棒性。

#### (4)分类识别

在端点检测算法监测到车辆行为事件的开始点后,充分利用车辆行为渐进变化过程中的信息,实时获取车辆行为数据,通过使用训练好的SVM模型进行行为分类,实现在行为变化的过程中对当前行为进行实时识别和预测。




图4 车辆行为识别的基本过程

#### 3.1 数据预处理

##### 3.1.1 轨迹数据预处理


车辆的运动轨迹可以用经纬度坐标点 $(x, y)$ 来表示,因一个完整的轨迹序列由一系列坐标点组成。一段轨迹长度为 $l$ 的序列可表示为 $L = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$ 。

本文中车辆的坐标点通过GPS来确定,但GPS信息可能会因为信号丢失、运动物体过快等原因造成数据不完整和不准确,以至于包含错误数据。这样的数据会对进一步的轨迹特征提取、训练、识别造成很大的负面影响。因此为了确保轨迹序列的有效性,本文需要对车辆轨迹进行相关的预处理操作,主要包括以下3个方面。


1)去除不完整轨迹序列。统计所获取的轨迹序列 $L$ 上轨迹点的个数 $n$ ,如果 $n$ 小于设定的阈值 $k$ ,则看作是不完整的序列,删除该序列。

2) 轨迹重构。对于那些轨迹点的个数  $n$  大于或等于设定阈值  $k$  的不完整序列,通过插值算法进行轨迹重构,从而恢复出车辆完整的轨迹。


3) 线性拟合。在获得完整的轨迹序列  $L$  后,使用最小二乘法<sup>[10]</sup>进行曲线拟合。这样不仅可以去除存在的异常点,也更能准确地描述出车辆行驶的运动趋势。本文中的拟合函数  $y=f(x)$  采用的是五次多项式函数,拟合后的轨迹点序列为  $L'=\{(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_l, f(x_l))\}$ 。



(a) 不完整轨迹



(b) 重构后的轨迹



(c) 拟合后的轨迹

图 5 轨迹数据预处理

图 5(a) 示出了某次车辆行驶的轨迹点原始图像,从中可以看出,虽然轨迹点数据来源于 GPS,且规定每隔 1s 采样一次,但实际收集过程中由于手机性能和信号等影响,轨迹数据可能会造成数据丢失现象,因此需要利用插值算法进行处理,其处理结果如图 5(b) 所示。插值算法可以通过插入 GPS 采样过程中丢失的位置信息来完善目标移动轨迹,但无法消除误差较大的轨迹信息对后期处理的影响,所以在保留整体特征的情况下,需要通过线性拟合算法来消除局部误差影响。

### 3.1.2 运行速度计算

虽然目前大部分手机的 GPS 可以提供速度这项数据,但在 GPS 信号丢失的情况下,速度数据也将同时丢失。为了避免 GPS 信号丢失造成的速度数据丢失以及部分手机不提供速度数据的问题,本文采用了速度计算模型来计算车辆的运行速度。测试结果如图 6 所示,其中菱格线表示的是从手机 GPS 模块中读取到的数据,方格线表示的是利用速度计算模型得到的数据。从图 6 的计算结果中可以看出,经过计算的速度值与 GPS 模块中所获取的速度基本一致,故可用于后续




图 6 GPS 测量的速度与“距离/时间”计算的速度

### 3.1.3 传感器数据预处理

在传感器数据的采集和传输过程中,不可避免地会受到大量噪声信号的干扰。在采集数据的过程中发现,当车辆经过的路面坑洼严重时,传感器数据会抖动得厉害,且非常不准确。因此,一方面需要对这样的数据进行剔除,增强样本的典型性,另一方面也需要对其他正确的信号进行去噪,提取出原始信号,以保证数据的真实性。本文使用小波变换<sup>[11]</sup>对原始传感器数据进行噪声和信号的分离。考虑到小波变换中阈值选择的问题,本文根据经验以及多次的实践,综合考虑降噪过程的准确性以及效率,对信号进行 3 层的多尺度分解,使用软阈值方法对信号进行降噪处理。图 7 示出了原始加速度信号及其小波降噪后的结果。其中 X 轴加速度、Y 轴加速度及 Z 轴加速度如图 7 所示。




图 7 原始加速度信号和降噪后的加速度信号

## 3.2 特征提取

### 3.2.1 轨迹序列编码

事实上,车辆的方向变化与车辆所在的地理位置并不相关。为了去除车辆行为识别与具体 GPS 位置点信息的关联,本文通过轨迹编码模型,即相邻轨迹点所产生的方向角作为描述车辆行为的特征参数。由于车辆在短时间内运行的距离远远小于地球的半径,因此把短时间内车辆的运动看作是在平面上的运行。以转弯为例,图 8 中的左转可以用  $L=\{1,1,1,1,2,2,2,3,3\}$  的编码方式表示。




图 8 左转的方向角序列

### 3.2.2 传感器数据特征提取

车辆行为识别实质上是一个模式识别的过程。在取得实

验所需的传感器原始数据之后,车辆行为识别能够利用模式识别的方法,即使用车辆行为的特征参数进行建模。因此,参数必须和车辆行为特征相关,且特征参数的数量和质量在一定程度上对于识别模型的识别效率极其重要。

尝试对传感器数据在时域和频域上分别进行分析,首先提取最大值、最小值、平均值、中值、方差等基于时域的静态统计特征以及基于快速傅里叶变换(Fast Fourier Transformation, FFT)上的频域特征作为特征参数。由于并不能确定频域特征的分布情况,因此若直接使用 FFT 的频域特征,很可能产生特征维度爆炸的问题。因此,还需要使用主成分分析法<sup>[12]</sup>(PCA)对数据进行降维,选取主要的特征参数,这样也能在一定程度上减少分类算法的运行时间,保证系统的实时性。

表 1 列出了各类车辆行为的三轴加速度传感器数据的平均最大值。为了方便展示和比较,将重力加速度方向即 X 轴数据减去  $9.8\text{m/s}^2$ 。从表 1 中可以看出, X 轴数据基本维持在  $[0, 1.5]$  区间之间。这反映出经过预处理操作之后,目前保存下来的数据受到地面不平的情况非常少。而纵向对比平均最大值后可以发现:转弯行为在 Y 轴和 Z 轴两个方向上的数据变化相对明显,而加速减速行为主要体现在 Z 轴方向。

表 1 平均最大值加速度统计/ $\text{m/s}^2$

车辆行为	X轴加速度	Y轴加速度	Z轴加速度
直行	0.63	1.05	1.25
左转	1.28	3.43	1.87
右转	1.28	3.28	1.96
U转	0.98	4.22	2.34
变道	1.16	3.21	2.12
倒车	0.41	0.98	1.06
加速	1.29	1.19	3.05
普通减速	1.18	1.15	3.15
急性减速	1.35	1.23	5.84

### 3.3 分类训练和识别

#### 3.3.1 SVM 分类模型和分类类型

鉴于智能手机端有限的内存和运算速度等特性,为确保车辆行为识别的准确率和实时性,选择支持向量机<sup>[13]</sup>作为智能手机端的车辆行为分类算法。SVM 方法是通过一个非线性映射  $\rho$ ,把样本空间映射到一个高维乃至无穷维的特征空间中,使得在原来的样本空间中非线性可分转化为在特征空间中的线性可分的问题。SVM 的最终决策函数只由少数的支持向量所确定,计算的复杂度取决于支持向量的数目,而不是样本空间的位数,这在某种程度上可以避免“维数”灾难,帮助剔除冗余样本。SVM 算法简单,而且具有较好的鲁棒性。

与已有研究相比,本文对车辆行为进行轨迹和速度两方面的判定,具体分类类别如图 9 所示,即一个车辆行为是轨迹和速度两种方面的衡量。




图 9 车辆行为根据轨迹和速度分别利用 SVM 进行分类

其中加速、减速指的是一段持续时间内的加速、减速过程,而短暂的加速、减速动作由于其时间过短、传感器精度和采样频率等限制,本文不对其进行检测,将其归类为“正常”。由于单次变道施加的力量较小,以及 GPS 定位精度等因素的影响,智能手机上的传感器检测到的数据变化特征不够明显,因此在本文中只对频繁变道做了研究。另外,由于急性减速在交通场景理解中具有十分重要的意义,将急性减速与普通减速进行了区分。而超速和缓行直接利用阈值进行判定,这里不再详细说明。

值得注意的是,SVM 一般适用于二分类的情况,因此必须扩展到多分类才能满足以上的分类需求。在学习过程中,使用 LIBSVM<sup>[14]</sup>进行分类实验。另外,SVM 的惩罚参数和核函数是影响分类结果的重要参数,经过多次实验的比较发现,使用 RBF 核函数的准确率最高。

#### 3.3.2 端点检测

车辆状态数据是一个随时间不断延伸的序列,记为  $R$ ,而车辆行为则被包含在这样的序列中,记为  $B_i, \forall i, B_i \in R$ 。在行为识别之前,需要从  $R$  中将  $B_i$  截取出来。传统的车辆行为识别中,主要使用滑动窗口的形式对原始数据进行提取。这种方式存在如下问题:

- 1) 滑动窗口的大小只能通过人为确定,窗口过大或者过小都会影响识别的准确率。
- 2) 对于一些连续的动作,滑动窗口的误检率较高(见图 10),监测的理想答案应该是 U 型转弯和右转弯,但在实际识别过程中,由于滑动窗口过小,监测结果多达 4 种状态。




图 10 滑动窗口下的 4 种检测结果

本文使用端点检测<sup>[15]</sup>算法来获知某种车辆行为的开始。根据对各种车辆行为的分析,发现车辆的各个行为的开始往往都伴随着加速度传感器测量结果的抖动,  $a(i)_y, a(i)_z$  分别表示时刻  $i$  加速度传感器 Y 轴、Z 轴方向的加速度分量。令  $a(i) = a(i)_y^2 + a(i)_z^2$ , 则判断的条件为:

$$\zeta = \frac{a(i) + a(i-1) + \dots + a(i-k-1)}{k}$$




图 11 端点检测的两种检测结果

上式为端点检测条件,当  $\zeta$  的值大于阈值  $H$  时,则认为时刻  $i$  是某个车辆状态的开始端点,需要进行数据的记录,期间每隔时间  $T$  对目标的移动数据进行一次全局特征提取和状态判断,不断矫正判断结果。当  $\zeta$  小于阈值  $L$  时,状态结

束,进行最终判断结果的矫正。当时间超过最大时间  $\max T$  时,则放弃当前状态的监测。根据实验证明,该算法能准确提取初始数据,提高行为识别率。如图 11 所示,圆形表示开始端点,叉形表示结束端点,可以看出,端点检测算法在这种情况下做出的判断更加合理。




图 12 端点检测

图 12 示出了一些典型情况下端点检测算法的工作情况,竖线表示的是车辆行为的起止点,没动的曲线分别表示 X 轴、Y 轴和 Z 轴的加速度。可以看出,大部分情况下端点检测算法总能检测到待检测状态的开始信号和结束信号。因此,本文提出的端点检测算法可以应用于之后的研究中,并能准确提取出车辆行为的数据段,减少误判情况的发生。

### 3.3.3 基于时间分段的行为识别和渐进矫正方法

基于时间分段矫正的行为识别算法(Behavior recognition algorithm based on the time segment),其核心思想是:通过端点检测算法检测车辆行为的开始,充分利用车辆行为为渐进变化过程中的信息,对车辆行为数据进行时域和频域的特征提取,放入 SVM 中进行分类识别,使算法能在行为变化的过程中对当前行为进行预测和实时识别,达到渐进矫正的目的。

图 13 示出了基于时间分段矫正的行为算法过程。

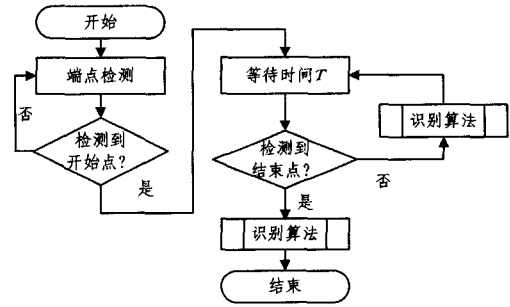


图 13 基于时间分段矫正的行为算法过程

如图 13 所示,整个车辆行为识别的步骤如下:

步骤 1 端点检测。循环检测,判断是否有数据端点出现。

步骤 2 记录数据。当检测到数据端点时,系统认为车辆行为开始,设置传感器数据到监听状态,不断记录数据。

步骤 3 分段矫正识别。设置计时器,使用步骤 2 中系统记录的车辆行为数据,每隔时间  $T$  调用一次 SVM 数据识别算法。

步骤 4 判断是否超时,若超时则最后调用一次 SVM 识别算法,并结束本次识别流程;否则跳转至步骤 2 继续识别。

车辆行为的实时判断,是在车辆行为发生过程中来判断车辆的行驶状态,即当前时刻车辆行为的判别结果并不一定代表针对该车完整驾驶行为的最终行为判断结果。在监测到数据端点之后,系统不断地获得新收集的数据进行车辆行为识别,可以认为这是一个不断完善车辆运行信息,将车辆行为从猜想行为到确认行为推进的过程,也是车辆行为算法渐进矫正的过程。

为了便于实验,本文使用数据收集 App 收集某种车辆行为的整个过程数据,并统一将其分为 5 段,每一个测试数据都从数据的起点开始,到特定的位置,形成 5 组分段数据,并将该分段数据作为训练数据来模拟基于时间分段的渐进过程,以提高算法的识别率和预测功能。如图 14 所示,分段数据分别是 0-1 数据段、0-2 数据段、0-3 数据段、0-4 数据段、0-5 数据段。




图 14 数据分段示意图

## 4 实验和分析

本文在安卓平台上开发了车辆行为数据收集应用程序。在数据收集时,通过手机支架将测试手机固定在车的前方,使用支架而不直接放置在车内是为了防止车辆行驶过程引起手机的滑动,尽量使得测试数据精确。用户在实际应用的过程中,如果手机的放置位置与本文实验有所差异,也可以通过坐标系转换的方式将数据还原到本文的放置方向。另外,为了

确保车辆行为识别的准确性,实验收集的样本数量必须足够大,并且包含尽可能多的行为特征。

4.1 实验结果

为了验证所提方法的有效性,本文对多种车辆行为状态进行了实验。由于 Android 操作系统版本众多,不同版本所支持的传感器类型有明显的差异,不同型号的手机配置在处理能力、存储能力上也参差不齐。在本次实验中,智能终端版本为 Samsung Galaxy S4(见表 2),传感器采样频率为 50Hz, GPS 采样频率为 1Hz, Android 系统版本号为 4.2.2。

表 2 Samsung Galaxy S4 硬件配置参数

硬件	参数
核心数	双 4 核
CPU	型号:三星 Exynos 5 Octa 5410 频率:1.8GHz
GPU	Imagination PowerVR SGX544 MP3
RAM 容量	2GB
ROM 容量	16GB
电池容量	2600mAh
传感器	内置 GPS、重力感应器、加速度传感器、电子罗盘传感器、光线传感器、温度传感器、湿度传感器、距离传感器等
屏幕	尺寸:5.0 英寸 分辨率:1920×1080 像素

为保证数据样本的平衡性,本文所有车辆行为类型的采集样本数量总共有 2070 条,每种分类样本均为 230 条。作为对比,直接将未分段数据作为训练样本,并用 5 组分段数据分别模拟车辆行为的过程数据来进行测试,其结果如表 3 所列。

表 3 未分段训练结果/%

	0-1 数据段	0-2 数据段	0-3 数据段	0-4 数据段	0-5 数据段
左转	8.26	37.83	53.91	78.70	91.30
右转	6.96	28.26	75.65	92.61	94.78
U 转	4.78	3.48	47.39	96.09	96.96
变道	4.78	17.39	49.13	87.39	92.6
直行	90.87	89.13	95.22	96.52	97.39
倒车	74.35	98.26	98.70	97.83	99.13
加速	0.43	0.43	24.78	83.48	93.04
普通减速	1.74	8.26	45.65	77.83	96.96
急性减速	3.91	3.48	3.43	3.48	96.09

表 4 列出了使用分段数据进行训练的 SVM 在测试中的表现。可以看出随着实验中车辆行为数据的逐渐完善,算法对车辆行为识别结果逐渐矫正,使得状态的识别率不断提高,最终达到一个较高的水平;未使用分段数据训练的 SVM 在测试时的识别准确率明显低于表 4,尤其是对急性减速的状态几乎无法检测。因此,使用分段数据进行车辆行为识别训练,可以有效地提高 SVM 的分类能力,且对车辆行为有一定的预见性,证明了本文所提方法的可行性。

表 4 分段训练结果/%

	0-1 数据段	0-2 数据段	0-3 数据段	0-4 数据段	0-5 数据段
左转	22.17	80.87	84.78	94.34	94.78
右转	32.61	75.65	90.87	94.78	95.22
U 转	15.22	59.13	86.09	95.22	96.52
变道	24.34	66.09	88.26	95.65	96.09
直行	87.39	91.74	96.96	95.22	97.39
倒车	32.17	92.61	97.82	98.70	99.13
加速	59.57	73.48	97.39	96.96	96.09
普通减速	76.52	78.26	94.78	96.52	97.65
急性减速	30.84	63.91	97.39	96.09	98.69

4.2 方法对比

将本文方法与文献[7]中的方法进行比较,实验结果如图 15 所示。文献[7]设计并实现了 iPhone4 平台上的 MIROAD 系统,该系统利用摄像机、加速度传感器、陀螺仪和 GPS,使用动态时间规整分类算法对车辆轨迹行为进行分类。其中,加速度传感器、陀螺仪的采集频率为 25Hz, GPS 采集频率为 1Hz,且仅用于设定速度数据。在特征方面,文献[7]用  $T = \{g_x, a_y, e_x\}$  来识别转弯,用  $L = \{g_y, a_z\}$  来识别加速和刹车。本文与文献[7]的异同具体如表 5 所列。




图 15 识别率结果比较

表 5 本文方法与文献[7]方法的比较

	文献[7]方法	本文方法
数据采集	摄像机 加速度传感器 陀螺仪 GPS(速度)	磁力计 加速度传感器 陀螺仪 GPS(经度、纬度、速度)
采集频率	GPS 1Hz 加速度传感器 25Hz 陀螺仪 25Hz	GPS 1Hz 加速度传感器 50Hz 陀螺仪 50Hz 磁力计 50Hz
手机平台	iPhone4	Samsung Galaxy S4
预处理	1Hz 低通滤波	轨迹预处理:不完整轨迹删除、轨迹重构、轨迹拟合、小波软阈值去噪
特征选择	转弯类 $T = \{g_x, a_y, e_x\}$ 刹车和加速 $L = \{g_y, a_z\}$	轨迹数据:方向角划分编码 速度数据:速度计算模型获取 传感器时域特征:最大值、最小值、中值、平均值、方差、标准差 传感器频域特征:FFT 特征
分类模型	DTW	SVM

从最终识别结果来看,本文所提方法在车辆轨迹行为识别方面具有较强且平衡的分类能力,可以基本准确地对车辆轨迹行为进行区分。

4.3 错误率分析

对直行、左转、右转和 U 转这 4 种典型轨迹状态进行分析。图 16—图 19 的横坐标表示 5 个数据分段,纵坐标表示各数据分段被分类的比重。

图 16 示出了直行的分类情况。由于直行行为的简单性和稳定性,其识别率一直维持在较高且缓慢上升的水平。




图 16 直行分类情况分析




图 17 左转分类情况统计




图 18 右转分类情况统计




图 19 U转分类情况统计

图 17 和图 19 分别示出了左转和 U 型转弯数据在车辆行为进行过程中随着数据的丰富而识别情况的变化。可以看出,在车辆行为之初,本文无法区别左转、U 型转弯以及直行这 3 种类型的行为,左转的开始阶段容易判别为直行,而 U 型转弯由于和左转弯路径轨迹相似,同样容易被检测为直行和左转。这也符合实际情况下,大多车辆在转弯时会进行直行行为的客观规律。随着状态的演进,到第 3 组数据时,状态基本可以被准确区分,且当车辆行为状态结束时,左转和 U 型转弯几乎可以被准确识别。

同样地,如图 18 所示,右转在行为最开始阶段判定仅为直行或右转两种情形,但随着轨迹数据的逐渐丰富,右转识别为直行的情况呈快速下降趋势,最终准确率能够达到 95% 以上。

**结束语** 为了提高车辆行为识别的准确率和实时性,本文提出了一种基于智能手机的车辆行为实时判别与渐进矫正方法。该方法利用 SVM 对车辆行为从轨迹、速度等车辆行为特征进行分析研究,并利用曲线拟合、速度计算、小波去噪等方法,实行了数据处理和特征提取。在整个识别过程中使用端点检测算法代替滑动窗口,提高了识别准确率。此外,本文提出基于时间分段来进行渐进矫正的车辆行为识别算法,充分利用车辆行为渐进变化过程中的信息,将提取到的特征放入 SVM 中进行分类识别,使得算法在行为变化过程中对当前行为进行实时预测和识别。本文通过实验证明了本文算法实时判别车辆行为的有效性和实用性。在以后的工作中,将针对本文研究存在的问题,加上坐标系的转换功能,使得手机可以任意放置,增强研究的实用性,同时还可以针对单次变道进行专门的特征分析,提高单次变道的识别率。

## 参考文献

- [1] Piciarelli C, Micheloni C, Foresti G L. Trajectory-Based Anomalous Event Detection[J]. *IEEE Transactions on Circuits & Systems for Video Technology*, 2008, 18(11): 1544-1554.
- [2] KAMIJO S, MATSUSHITA Y, IKEUCHI K, et al. Traffic monitoring and accident detection at intersections[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2000, 1(2): 108-118.
- [3] KAMRAN S, HAAS O. A Multilevel Traffic Incidents Detection Approach: Identifying Traffic Patterns and Vehicle Behaviours using real-time GPS data[C]// *Intelligent Vehicles Symposium*, 2007 IEEE. IEEE, 2007: 912-917.
- [4] LY M V, MARTIN S, TRIVEDI M M. Driver classification and driving style recognition using inertial sensors[C]// *Intelligent Vehicles Symposium (IV)*, 2013 IEEE. IEEE, 2013: 1040-1045.
- [5] REDDY S, MUN M, BURKE J, et al. Using mobile phones to determine transportation modes[J]. *ACM Transactions on Sensor Networks*, 2010, 6(2): 662-701.
- [6] FENG T, TIMMERMANS H J P. Transportation mode recognition using GPS and accelerometer data[J]. *Transportation Research Part C Emerging Technologies*, 2013, 37(3): 118-130.
- [7] JOHNSON D A, TRIVEDI M M. Driving style recognition using a smartphone as a sensor platform[C]// *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2011: 1609-1615.
- [8] WANG X H, CONG Z H, FANG L L, et al. Determination of Real-time Vehicle Driving Status Using HMM[J]. *Acta Automatica Sinica*, 2013, 39(12): 2131-2142. (in Chinese)  
王相海, 丛志环, 方玲玲, 等. 基于 HMM 的车辆行驶状态实时判别方法研究[J]. *自动化学报*, 2013, 39(12): 2131-2142.
- [9] HAO J Y, HAO S, LI C, et al. Vehicle behavior understanding based on movement string[C]// *12th International IEEE Conference on Intelligent Transportation Systems*, 2009 (ITSC'09). IEEE, 2009: 1-6.
- [10] LAWSON C L, HANSON R J. Solving least squares problems [M]. Englewood Cliffs, NJ: Prentice-hall, 1974.
- [11] ANTONINI M, BARLAUD M, MATHIEU P, et al. Image coding using wavelet transform[J]. *IEEE Transactions on Image Processing*, 1992, 1(2): 205-220.
- [12] JOLLIFFE I. Principal component analysis[M]. John Wiley & Sons, Ltd, 2002.
- [13] HEARST M A, DUMAIS S T, OSMAN E, et al. Support vector machines[J]. *Intelligent Systems and their Applications*, IEEE, 1998, 13(4): 18-28.
- [14] CHANG C C, LIN C J. LIBSVM: A library for support vector machines[J]. *ACM Transactions on Intelligent Systems & Technology*, 2007, 2(3): 389-396.
- [15] SHEN J, HUNG J, LEE L. Robust entropy-based endpoint detection for speech recognition in noisy environments[C]// *ICSLP*. 1998, 98: 232-235.