

DOI:10.11992/tis.201504022

网络出版地址: <http://www.cnki.net/kcms/detail/23.1538.tp.201509030.1456.002.html>

智能手机车辆异常驾驶行为检测方法

周后飞^{1,2,3}, 刘华平^{2,3}, 石红星⁴

(1.重庆交通大学 土木工程学院,重庆 400074; 2.清华大学 计算机科学与技术系,北京 100084; 3.清华大学 智能技术与系统国家重点实验室,北京 100084; 4.北京城建道桥建设集团有限公司,北京 100080)

摘要:将智能手机作为车辆异常驾驶行为检测工具,设计了一种车辆异常驾驶行为检测方法和系统。系统通过获取车载智能手机内部的加速度传感器数据、陀螺仪传感器数据以及磁场传感器数据,经坐标旋转和特征提取,并利用基于核方法极限学习机(核 ELM)得到的驾驶行为在线分析算法,以实现能实时识别包括频繁变道、频繁变速及急刹车在内的多种车辆异常驾驶行为,并在车辆出现异常驾驶行为时开启报警语音。测试结果表明,基于核 ELM 算法的驾驶行为分类器性能比基于支持向量机(SVM)算法更好,提出的异常驾驶行为检测系统能有效识别各种驾驶行为。

关键词:智能手机;异常驾驶行为检测;传感器;核方法;极限学习机;支持向量机**中图分类号:**TP29;U49 **文献标志码:**A **文章编号:**1673-4785(2016)01-0410-08

中文引用格式:周后飞,刘华平,石红星,等.智能手机车辆异常驾驶行为检测方法[J].智能系统学报,2016,02(1):410-417.

英文引用格式:ZHOU Houfei, LIU Huaping, SHI Hongxing, et al. Abnormal driving behavior detection based on the smart phone [J]. CAAI Transactions on Intelligent Systems, 2016, 02(1): 410-417.

Abnormal driving behavior detection based on the smart phone

ZHOU Houfei^{1,2,3}, LIU Huaping^{2,3}, SHI Hongxing⁴

(1.School of Civil & Architecture Engineering, Chongqing Jiaotong University, Chongqing 400074, China; 2. Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China; 3. State Key Laboratory of Intelligent Technology and Systems, Tsinghua University, Beijing 100084, China; 4. Road and Bridge Construction Group Co., Ltd. of Beijing, Beijing 100080, China)

Abstract: Using the smart phone as a tool for detecting abnormal driving behavior, this paper designs an abnormal driving behavior detection method and a practical system. First, the system obtains data from the acceleration, magnetic, and gyroscope sensors of an on-board smart phone. Then, through coordinate rotation, feature extraction, and an online driving behavior analysis algorithm, which is based on the kernel extreme learning machine (ELM) algorithm, the system identifies real-time abnormal driving behavior, including frequent lane-changing, frequent speed-changing, and emergency braking. It then sets off an alarm when abnormal driving behavior has been identified. Test results indicate that the driving behavior classifier, which is based on the kernel ELM algorithm, performs better than the support vector machine algorithm. In addition, the proposed abnormal driving behavior detection system can effectively identify various driving behaviors.

Keywords: smart phone; abnormal driving behavior detection; sensor; kernel method; extreme learning machine (ELM); support vector machine

近年来,国内外研究人员相继研究利用智能手机识别各种行为。目前,基于智能手机的模式识别

研究主要集中在人体行为识别领域^[1-6],但也有部分学者尝试将智能手机应用到车辆驾驶行为识别方面。其中,Dai 等^[7]将车载智能手机的加速度和方向传感器数据作为车辆的运行参数来检测醉驾行

收稿日期:2015-04-09. 网络出版日期:2015-09-30.

基金项目:国家重点基础研究与发展计划项目(2013CB329403).

通信作者:刘华平.hpliu@tsinghua.edu.cn.

为。Paefgen 等^[8]用车载智能手机传感器信号来评估各类驾驶行为,但算法鲁棒性较弱;Xu 等^[9]利用车载智能手机拍摄照片,开展了基于人眼图像的疲劳驾驶检测技术研究。Eren^[10]等利用车载智能手机加速度传感器、陀螺仪传感器、磁场传感器数据来识别车辆的驾驶行为,并把车辆驾驶行为分为了安全和不安全两大类。Fazeen^[11]等比较了车载智能手机的加速度传感器数据和专业设备采集的车辆行驶过程中的加速度数据,结果显示,两者高度吻合,车载智能手机的加速度传感器数据可以用来表征车辆自身的加速度。在利用车载智能手机进行交通事故检测方面,李伟健等^[12]通过设定手机加速度传感器数值变化阈值来检测车辆碰撞事故;赵龙等^[13]在李伟健等基础上,将基于单部车载手机的碰撞事故识别技术提升到基于多部车载手机。但文献[11-13]均通过阈值法来进行事故判断,识别效果有待

进一步改善。可见,基于智能手机的驾驶行为识别研究还处于探索阶段,研究工作有待进一步推进和完善。为此,本文开展了基于智能手机的车辆异常驾驶行为检测技术研究。论文主要工作有:

- 1) 利用智能手机实时采集车体运动状态,提出了异常驾驶行为检测方法框架,并针对左变道、右变道、加速、减速、急刹车、正常行驶等 6 类驾驶行为分析了手机传感器数据的特性;
- 2) 设计了基于核 ELM 的驾驶行为在线分析算法和异常驾驶行为检测算法;
- 3) 开发了“车辆异常驾驶行为监控系统”软件,并在实际运行中测试了其性能。

1 方法框架

本文提出的异常驾驶行为检测方法框架如图 1 所示。

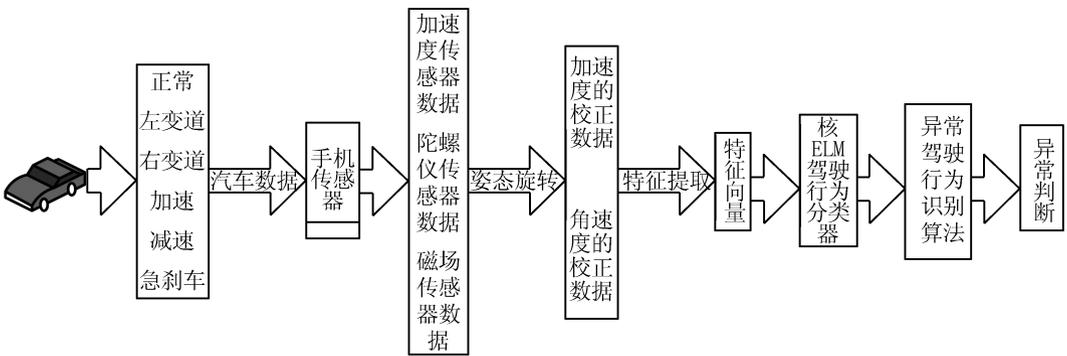


图 1 方法框架

Fig.1 The framework of the proposed method

方法流程包括:

- 1) 利用车载手机的运动状态表征车体运动状态;
- 2) 通过车载手机内部的传感器获得手机的动态参数;
- 3) 将获得的手机动态参数旋转校正至在特定坐标系下的数据;
- 4) 提取经旋转校正后的手机动态参数的特征;
- 5) 用分类器识别车载手机的运动状态,并在此基础上识别车辆是否出现本文所定义的异常行为。

2 车载手机数据分析

为分析车载手机在车辆不同驾驶行为状态下的动态参数特征,采集了手机在车辆加速、减速、左变道、右变道、急刹车、正常行驶等多种情况下的数据,数据包括手机加速度传感器数据 $\mathbf{A} = [a_x \ a_y \ a_z]$ (其中, a_x 表示手机 X 轴的加速度, a_y 表示 Y 轴的加速度, a_z 表示 Z 轴的加速度,单位 m^2/s)、陀螺仪传感器数据 $\mathbf{G} = [g_x \ g_y \ g_z]$ (其中 g_x 表示绕手机 X 轴的角

速度, g_y 表示绕 Y 轴的角速度, g_z 表示绕 Z 轴的角速度,单位 rad/s), 以及数据采集时刻 t 。

数据采集过程中,手机按照手机体坐标系 Y 轴正方向前与车头正向平行, Z 轴垂直于水平面向上的姿态放置(把这种放置姿态叫做“标准姿态”,采集的数据叫做“标准数据”)。手机体坐标系如图 2 所示。

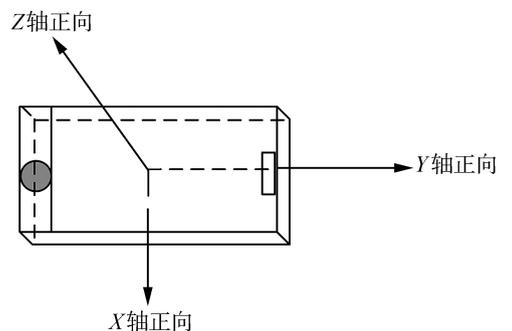


图 2 手机体坐标系

Fig.2 Coordinate system of the smart phone

采集数据同时,人为标定车辆的加速起始时间 $T_{ai}(i=1,2,\dots)$ 和终止时间 $T_{aj}(j=1,2,\dots)$ 、减速起始时间 $T_{di}(i=1,2,\dots)$ 和终止时间 $T_{dj}(j=1,2,\dots)$ 、左变道起始时间 $T_{li}(i=1,2,\dots)$ 和终止时间 $T_{lj}(j=1,2,\dots)$ 、右变道起始时间 $T_{ri}(i=1,2,\dots)$ 和终止时间 $T_{rj}(j=1,2,\dots)$ 、急刹车起始时间 $T_{si}(i=1,2,\dots)$ 和终止时间 $T_{sj}(j=1,2,\dots)$ 。

对比手机内部存储的时间 t 和人为标定的驾驶行为为起始时间和终止时间,提取从 $T_{ai}(i=1,2,3,\dots)$ 到 $T_{aj}(j=1,2,\dots)$ 、 $T_{di}(i=1,2,\dots)$ 到 $T_{dj}(j=1,2,\dots)$ 、 $T_{li}(i=1,2,\dots)$ 到 $T_{lj}(j=1,2,\dots)$ 、 $T_{ri}(i=1,2,\dots)$ 到 $T_{rj}(j=1,2,\dots)$ 和 $T_{si}(i=1,2,\dots)$ 到 $T_{sj}(j=1,2,\dots)$ 时间段内的手机三轴加速度数据 $\mathbf{A}=[a_x \ a_y \ a_z]$ 和绕三轴角速度数据 $\mathbf{G}=[g_x \ g_y \ g_z]$ 作分析。

车载手机传感器数据在几种车辆驾驶行为状况下的参数变化如图 3 所示(每幅图片的第 1 张表示 X 轴参数变化,第 2 张是 Y 轴参数变化,第 3 张是 Z 轴参数变化)。

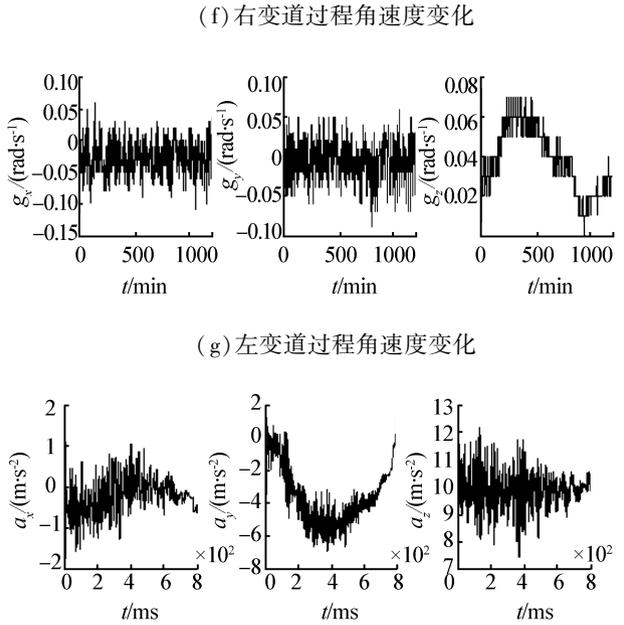
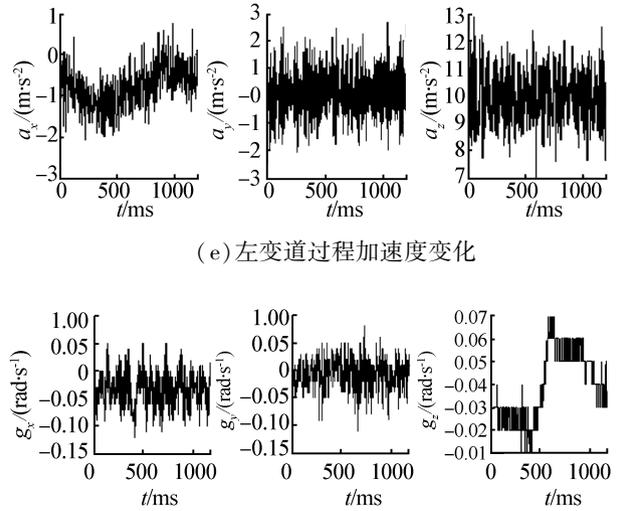
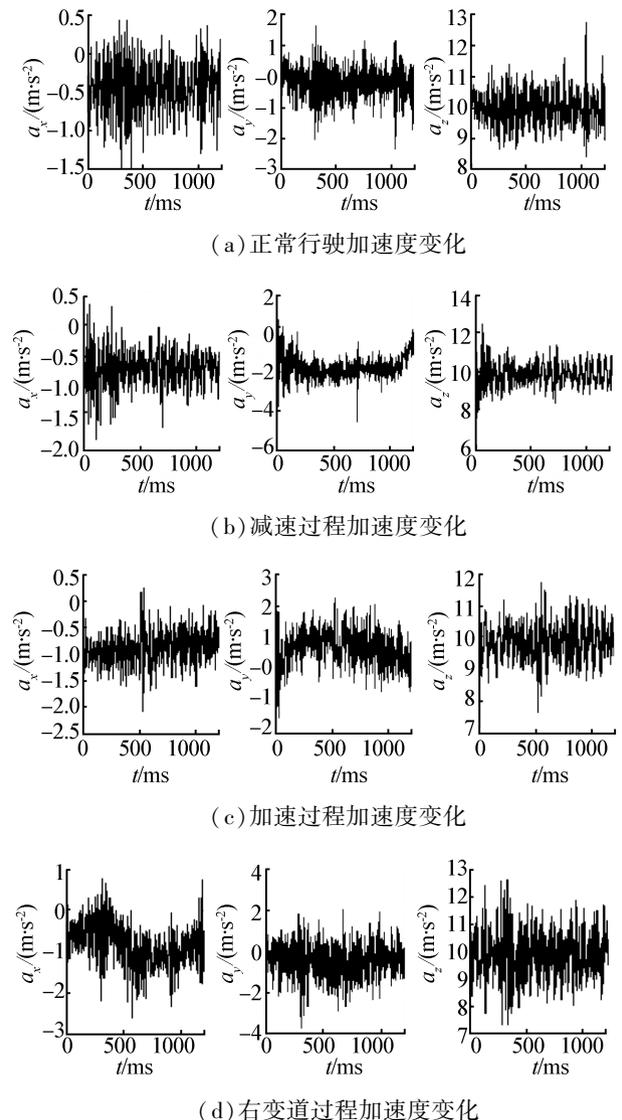


图 3 不同驾驶行为参数变化图

Fig. 3 Parameters curves corresponding to various driving behaviors

- 1) 分析图 3(a),手机三轴加速度在车辆正常行驶过程中数据特征不明显。
- 2) 分析图 3(b),手机 Y 轴加速度在车辆减速行驶过程中逐步由 0 减小至负值,车辆完成减速趋于平稳后又返回 0 值,Y 轴加速度数据特征明显。
- 3) 分析图 3(c),手机 Y 轴加速度在车辆加速行驶过程中逐步由 0 增加至正值,车辆完成加速趋于平稳后又返回 0 值,Y 轴加速度数据特征明显,但与减速过程恰好相反。
- 4) 分析图 3(d)和图 3(f),手机 X 轴加速度和绕 Z 轴角速度在车辆右变道行驶过程中数据特征明显。

5)分析图 3(e)和图 3(g),手机 X 轴加速度和绕 Z 轴角速度在车辆左变道行驶过程中数据特征明显,但与右变道过程恰好相反。

6)分析图 3(h),手机 Y 轴加速度在急刹车过程中逐步由 0 减小至负值,车辆完成刹车趋于平稳后又返回 0 值。Y 轴加速度数据特征与减速过程类似,但变化幅度远大于正常减速过程。

综合分析 6 种驾驶行为,车载手机的三轴加速度在车辆正常行驶过程中无明显波动,但在其他几种车辆驾驶行为情况下,手机三轴加速度数据均有明显变化,而变道过程(包括左右变道)中绕 Z 轴角速度数据特征也很明显。

3 车辆异常驾驶行为检测算法

基于对传感器数据的深入分析,提出了一种车辆异常驾驶行为检测算法,并开发了一款基于该算法的“车辆异常驾驶行为检测系统”,系统检测算法流程如图 4 所示。

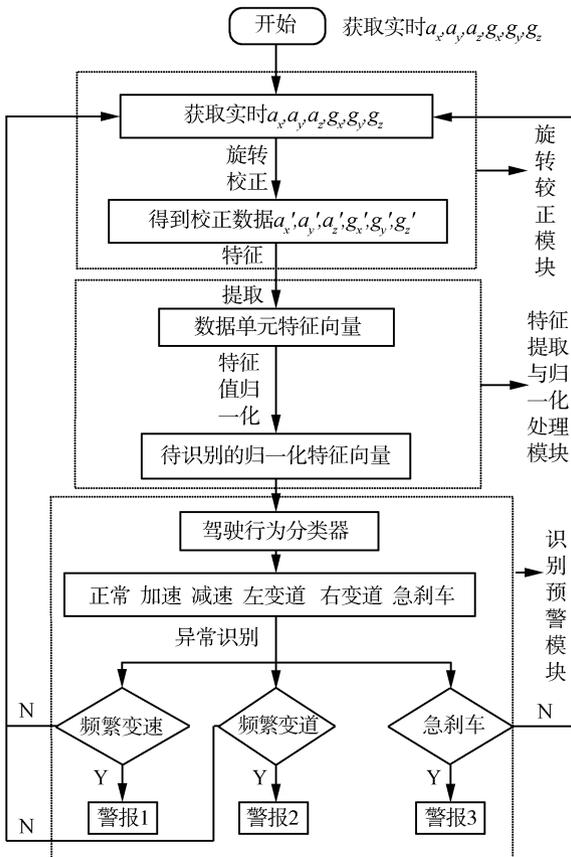


图 4 系统检测算法

Fig.4 Detection algorithm of system

3.1 手机动态参数旋转校正

车辆异常驾驶行为检测系统启动后,按照 100 Hz 的频率读取车载手机的三轴加速度数据和三

轴角速度数据。

若手机在系统运行过程中处于 X 轴与车体横向水平参照线(如图 5 所示)平行,而 X-Y 平面处于非水平的姿态时,系统对数据进行旋转校正,将其旋转为前述“标准姿态”下的数据。校正算法为:

1)获取夹角:根据提取的手机三轴加速度数据 $A=[a_x \ a_y \ a_z]$ 和三轴环境磁场数据 $M=[m_x \ m_y \ m_z]$ (m_x 表示手机 X 轴的磁场环境数据, m_y 表示 Y 轴磁场环境数据, m_z 表示 Z 轴磁场环境数据,均由手机磁场传感器获得),利用融合三轴加速度数据和三轴环境磁场数据的算法(具体算法专利归传感器公司所有),计算得到手机翻滚角 α 和俯仰角 β , α 和 β 分别表示手机沿 X 轴方向与水平面的夹角和沿 Y 轴方向与水平面的夹角。

2)数据旋转:基于空间三维坐标旋转方法,将三轴加速度数据 $A=[a_x \ a_y \ a_z]$ 和角速度数据 $G=[g_x \ g_y \ g_z]$ 分别旋转至“标准姿态”下的虚拟水平面为 $A'=[a_x' \ a_y' \ a_z']$ 和 $G'=[g_x' \ g_y' \ g_z']$ 。旋转后的手机虚拟姿态如图 5 所示。

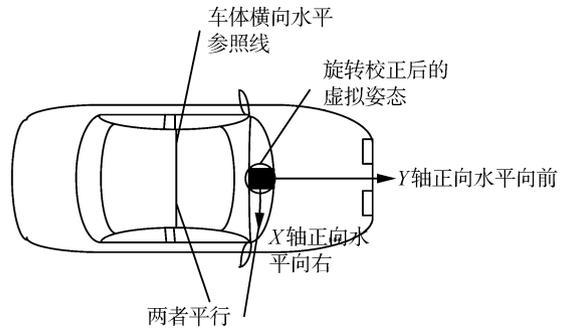


图 5 手机数据旋转校正

Fig.5 Data correction of smart phone

数据旋转形式如式(1)和式(2):

$$\begin{bmatrix} a_x' \\ a_y' \\ a_z' \end{bmatrix} = R_{oc}^a \cdot A^T =$$

$$\begin{bmatrix} \cos \beta & 0 & \sin \beta \\ \sin \alpha \sin \beta & \cos \alpha & -\sin \alpha \cos \beta \\ -\sin \beta & \cos \alpha & \sin \alpha \end{bmatrix} \cdot \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix} \quad (1)$$

$$\begin{bmatrix} g_x' \\ g_y' \\ g_z' \end{bmatrix} = R_{oc}^g \cdot G^T =$$

$$\begin{bmatrix} 1 & \sin \alpha \cdot \tan \beta & \cos \alpha \cdot \tan \beta \\ 0 & \cos \alpha & -\sin \alpha \\ 0 & \sin \alpha / \cos \beta & \cos \alpha / \cos \beta \end{bmatrix} \cdot \begin{bmatrix} g_x \\ g_y \\ g_z \end{bmatrix} \quad (2)$$

其中,加速度旋转矩阵 cR_a 为

$$R_{oc}^a = R(\alpha, \beta) = R_x R_y = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \alpha & \sin \alpha \\ 0 & -\sin \alpha & \cos \alpha \end{bmatrix} \begin{bmatrix} \cos \beta & 0 & -\sin \beta \\ 0 & 1 & 0 \\ \sin \beta & 0 & \cos \beta \end{bmatrix} = \begin{bmatrix} \cos \beta & 0 & \sin \beta \\ \sin \alpha \sin \beta & \cos \alpha & -\sin \alpha \cos \beta \\ -\sin \beta & \cos \alpha & \sin \alpha \end{bmatrix} \quad (3)$$

角速度旋转矩阵 cR_g 为

$$R_{oc}^g = \begin{bmatrix} 1 & \sin \alpha \cdot \tan \beta & \cos \alpha \cdot \tan \beta \\ 0 & \cos \alpha & -\sin \alpha \\ 0 & \sin \alpha / \cos \beta & \cos \alpha / \cos \beta \end{bmatrix} \quad (4)$$

旋转顺序为:

第 1 次旋转:先绕 X 轴将 Y 轴旋转至与水平面平行,手机体相对坐标系由 X-Y-Z 旋转至 X'-Y'-Z',如图 6(a)所示;

第 2 次旋转:再绕 Y'轴将 X'轴旋转至与水平面平行,手机体相对坐标系由 X'-Y'-Z'旋转至 X''-Y''-Z'',如图 6(b)所示。

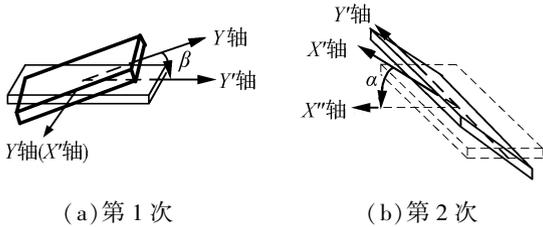


图 6 手机姿态旋转

Fig.6 Attitude rotation of smart phone

3.2 数据单元特征提取

为保证系统的实时性,把系统识别窗口设置成 2 s 时长,将窗口内经过旋转处理的加速度和角速度数据作为一个数据单元来进行识别。

由于手机传感器数据获取接口的原因,导致在 100 Hz 的数据更新频率下,400 次数据才是一个数据单元,故每个数据单元是 400×6 的矩阵,矩阵的 6 列数据为 a_{xi}' , a_{yi}' , a_{zi}' , g_{xi}' , g_{yi}' , g_{zi}' ($i = 1, 2, \dots, 400$)。

考虑到智能手机的计算能力,故设定的相邻窗口不重叠。图 7 显示了系统读取单元数据使用的连续窗口,其中横坐标为时间。

系统实时提取数据单元的特征值,一个数据单元的特征值组成一个特征向量。提取的特征值如表 1 所示。

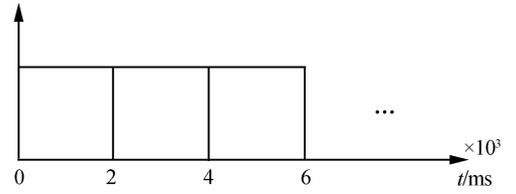


图 7 取值窗口

Fig.7 Data capturing windows

表 1 提取的特征值

Table 1 The extracted features

表达式	说明
$\mu_{xj} = \frac{1}{l} \sum_{i=1}^l X_i^j$	第 j 列数据的平均值
$\sigma_{xj}^2 = \frac{1}{l} \sum_{i=1}^l (X_i^j - \mu_{xj})^2$	第 j 列数据的方差
$\max_{xj} = \text{maximum}(X^j)$	第 j 列数据的最大值
$\min_{xj} = \text{minimum}(X^j)$	第 j 列数据的最小值
$\text{range}(X^j) = \max_{xj} - \min_{xj}$	第 j 列数据的幅度
$\text{mcr}_{xj} = \frac{1}{l-1} \sum_{i=1}^{N-1} \gamma \{ (X_i^j - \mu_{xj}) (X_{i+1}^j - \mu_{xj}) < 0 \}$	第 j 列数据的平均交叉率, γ 为指示函数
$\text{rms}_{xj} = \sqrt{\frac{1}{l} \sum_{i=1}^l X_i^j{}^2}$	第 j 列数据的均方根
$\text{kurt}_{xj} = \frac{1}{l\sigma_{xj}^4} \sum_{i=1}^l (X_i^j - \mu_{xj})^4$	第 j 列数据的偏度
$\text{corr}_{x^a x^b} = \frac{1}{l\sigma_{x^a} \sigma_{x^b}} \sum_{i=1}^l (X_i^a - \mu_{x^a})(X_i^b - \mu_{x^b})$	第 a 列数据与第 b 列数据的相关系数($a \neq b$)
$\text{SMA}_a = \frac{1}{l} \sum_{i=1}^l (X_i^1 + X_i^2 + X_i^3)$	加速度平均幅度面积

$$\text{EE}_a = \frac{1}{l} \sum_{i=1}^l \sqrt{X_i^1{}^2 + X_i^2{}^2 + X_i^3{}^2} \quad \text{加速度平均能量消耗}$$

$$\text{SMA}_g = \frac{1}{l} \sum_{i=1}^l (|X_i^4| + |X_i^5| + |X_i^6|) \quad \text{角速度平均幅度面积}$$

$$\text{EE}_g = \frac{1}{l} \sum_{i=1}^l \sqrt{X_i^4{}^2 + X_i^5{}^2 + X_i^6{}^2} \quad \text{角速度平均能量消耗}$$

注: X_i^j 表示数据单元第 i 行,第 j 列处数值, l 表示单元的行数,这里 $l = 400$

3.3 特征值归一化处理

为消除量纲的影响,同时把各个特征值的尺度控制在相同的范围内,在系统中设置特征向量归一化处理模块,采用的数据归一化映射关系为

$$f: x_i' = \frac{(y_{\max} - y_{\min}) * (x_i - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min} \quad (5)$$

式(5)中, y_{\max} 和 y_{\min} 是目标映射区间的上下限,

根据需要设定; x_{\max} 是所有特征值分量的最大值, x_{\min} 是所有特征值分量的最小值, x_i 是待处理的特征值, x_i' 是归一化处理后的特征值。这里选择 $y_{\min} = -1$ 和 $y_{\max} = 1$ 来归一化特征向量。

3.4 驾驶行为识别

提取车载手机传感器信号特征后,设计基于核 ELM 算法的分类器来识别各种驾驶行为。

极限学习机(ELM, extreme learning machine)是一种快速的单隐层神经网络(SLFN)训练算法,最早由南洋理工大学黄广斌教授等^[14]于 2004 年提出;结合支持向量机(SVM, support vector machine)、LS-SVM(least square support vector machine)及 P-SVM(Proximal Support vector machine)等方法的学习原理^[15-16],黄广斌等又在 2012 年提出了核 ELM 算法^[17]。与 SVM、LS-SVM、P-SVM 及原始的 ELM 算法相比,核 ELM 算法的参数敏感性更低(特别是对隐层节点数),且在隐层节点数足够大的情况下,算法便能获得较高的准确率,从而缩减了参数调优时间。此外,核 ELM 算法不用计算隐层输出矩阵,只须通过计算核函数 $k(x, x_i)$ 来确定最终的输出。

基于核 ELM 算法的驾驶行为学习过程为:

1)由输入的驾驶行为特征向量训练集确定最优输出权重: $\beta = H^T (I/C + HH^T)^{-1} T$ 。

2)由输入的驾驶行为特征向量测试集得到驾驶行为分类器的输出函数:

$$f(x) = h(x)\beta = h(x)H^T (I/C + HH^T)^{-1} T$$

记 $k(x, x_i) = h(x) \cdot h^T(x_i)$, $\Omega_{ELM} = HH^T$, $(\Omega_{ELM})_{ij} = h(x_i) \cdot h(x_j) = k(x_i, x_j)$ 。则驾驶行为的核 ELM 分类器的输出为

$$f(x) = h(x)H^T (I/C + HH^T)^{-1} T = \begin{bmatrix} k(x, x_1) \\ k(x, x_2) \\ \vdots \\ k(x, x_N) \end{bmatrix}^T (I/C + \Omega_{ELM})^{-1} T \quad (6)$$

式中: I 为常向量, T 为只与训练集标签相关的向量,而核矩阵 Ω_{ELM} 只和训练阶段输入的驾驶行为特征向量数据 x_i 及样本的个数 N 有关,需要人为指定的参数只有正则项系数 C 和核函数 $k(x, x_i)$ (核中包含核参数 γ)。

3.5 异常驾驶行为识别

实现驾驶行为识别后,需在此基础上进一步判断车辆是否出现异常驾驶行为。对此,在系统识别模块设定一个识别时间窗口 $[t_i, t_j]$ 和该窗口内的变道次数阈值 n_s 、变速次数阈值 s_s 。

1)若系统在窗口 $[t_i, t_j]$ 内识别出的变道(包括

左右两种变道)次数为 n ,且 $n > n_s$,则判定车辆出现频繁变道的危险行为,并立即触发“频繁变道”报警语音,以提醒驾驶员进行安全驾驶。

2)若系统在窗口 $[t_i, t_j]$ 内识别出的变速(包括加速和减速)次数为 s ,且 $s > s_s$,则判定车辆出现频繁加减速的危险行为,并立即触发“频繁加减速”报警语音,以提醒驾驶员进行安全驾驶。

3)若系统在窗口 $[t_i, t_j]$ 内识别出急刹车行为,则判定车辆出现急刹车的危险行为,并立即触发“急刹车”报警语音,以提醒驾驶员进行安全驾驶。

4 实验验证

4.1 驾驶行为分类器测试

将采集的 6 种驾驶行为数据集中 630 个样本作为训练集,剩下的 629 个样本作为测试集,并分别测试核 ELM 算法和 SVM 算法设计的驾驶行为分类器的性能。

采用核 ELM 算法来设计驾驶行为分类时,核函数选用高斯核(RBF),正则项系数 C 和核参数 γ 在范围 $\log_2 C = [-20, 20]$, $\log_2 \gamma = [-20, 20]$ 内均按照步长 1 等间距取值。测试结果如图 8 所示。

采用 SVM 算法来设计驾驶行为分类时,核函数选用高斯核(RBF),惩罚系数 C 和核参数 γ 取值范围同上。测试结果如图 9 所示。

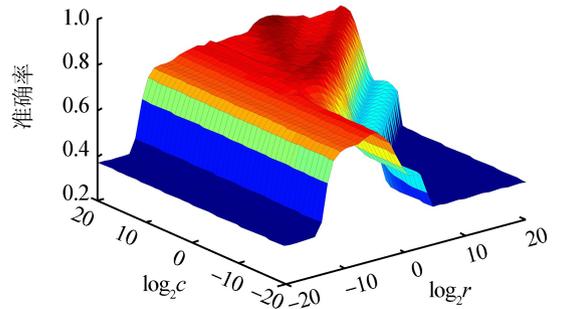


图 8 核 ELM 测试结果

Fig.8 Kernel ELM test results

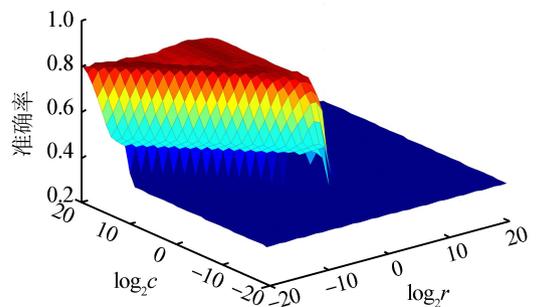


图 9 SVM 测试结果

Fig.9 SVM test results

分析图 8,采用核 ELM 算法设计的驾驶行为分类器在 $A = \{(\log_2 C, \log_2 \gamma) \mid \log_2 C \in [-10, 20], \log_2 \gamma \in [-10, 20]\}$ 及 $B = \{(\log_2 C, \log_2 \gamma) \mid \log_2 C \in [-20, 20], \log_2 \gamma \in [-10, 0]\}$ 两个区域内的正确识别率达到 81% 左右,且当 $C = 104\ 857\ 6, \gamma = 206.830\ 9$ 时正确识别率最高,达到 81.88%,此时的测试运行时间为 0.020 3 s。

分析图 9,采用 SVM 算法设计的驾驶行为分类器仅在 $D = \{(\log_2 C, \log_2 \gamma) \mid \log_2 C \in [10, 20], \log_2 \gamma \in [-10, 5]\}$ 区域内的正确识别率较高,达到 80% 左右,且当 $C = 101.5937, \gamma = 0.040\ 8$ 时正确识别率最高,为 80.76%,而此时的测试运行时间为 0.817 2s。

可见,基于核 ELM 算法的驾驶行为分类器相比基于 SVM 的驾驶行为分类器有如下优点:

- 1) 对参数 C 和 γ 的敏感性更低;
- 2) 整体正确识别率更高;
- 3) 时间复杂度更低,实时性更强。

故本文采用核 ELM 算法设计驾驶行为分类器。

4.2 系统测试

为了测试系统性能,本文开展了系统测试试验。试验路段为北京市房山区区长阳镇长阳路一段路面平坦且车辆较少的路段,如图 10 所示。



图 10 试验路段

Fig.10 Experiment road

系统测试试验采用的驾驶行为分类器的主要参数为:核函数为高斯核 (RBF), $C = 104\ 857\ 6, \gamma = 206.830\ 9$; 而最优输出权重 β 是一个 630×4 的矩阵,限于篇幅,在此不列出。

本次试验中,4 位志愿者共做了 150 次变速实验,140 次变道实验,115 次急刹车实验,约 142 次正常行驶实验。系统运行界面如图 11 所示,系统识别结果如表 2 所示。由表 2 可知,系统对变速、急刹车、正常行驶等行为识别效果较好,但对变道行为识别效果较差。变道实例有 140 个,其中 57 个被正确分类,67 个被误判为变速,7 个被误判为正常行驶,9 个被误判为急刹车,但这合乎常理,因为变道过程中经常伴随减速行为,只是有时候减速行为特征比变道行为特征更明显。



图 11 系统运行界面

Fig.11 System operation interface

表 2 4 种车辆驾驶行为识别结果

Table 2 Four kinds of vehicle driving behavior recognition results

行为类别	识别结果				识别率/%
	变速	变道	正常	急刹车	
变速	97	36	5	12	64.67(97/150)
变道	67	57	7	9	40.71(57/140)
正常	18	10	114	0	80.28(114/142)
急刹车	9	2	2	102	88.70(102/115)

5 结束语

文章通过车载手机获取车辆运行动态参数,并采用核 ELM 算法训练出了鲁棒性较强的车辆驾驶行为分类器,与基于 SVM 算法的分类器相比,前者对车辆驾驶行为的识别效果优于后者。提出的“车辆异常驾驶行为检测系统”对变速、急刹车、正常行驶等行为的识别效果令人满意。在后续研究中,我们将改进车辆变道行为识别方法,并研究手机传感器数据实时滤波技术,以剔除噪声干扰,提高识别精度。此外,在检测到车辆异常驾驶行为信息后,如何将信息上传至监控端,而监控端在接收信息后如何将信息反馈至监测路网内的车辆也是今后努力的方向^[18]。

参考文献:

[1] KWAPISZ J R, WEISS G M, MOORE S A. Activity recog-

- tion using cell phone accelerometers [C]//Proceedings of the Fourth International Workshop on Knowledge Discovery from Sensor Data. Washington, DC, USA, 2010, 12(2): 74-82.
- [2] FANG S H, LIANG Y C, CHIU K M. Developing a mobile phone-based fall detection system on android platform [C]//Proceedings of Computing, Communications and Applications Conference. Hong Kong, China, 2012: 143-146.
- [3] VIET V Q, LEE G, CHOI D. Fall detection based on movement and smart phone technology [C]//Proceedings of IEEE RIVF International Conference on Computing and Communication Technologies, Research, Innovation, And Vision For The Future. Ho Chi Minh City, Vietnam, 2012: 1-4.
- [4] ZHANG Shumei, MCCULLAGH P, NUGENT C, et al. Activity monitoring using a smart phone's accelerometer with hierarchical classification [C]//Proceedings of the 6th International Conference on Intelligent Environments. Kuala Lumpur, Malaysia, 2010: 158-163.
- [5] ZHAO Zhongtang, CHEN Yiqiang, LIU Junfa, et al. Fall detecting and alarming based on mobile phone [C]//Proceedings of Ubiquitous Intelligence & Computing and the 7th International Conference on Autonomic & Trusted Computing. Xi'an, China, 2010: 494-497.
- [6] BAI Yingwen, WU S C, TSAI C L. Design and implementation of a fall monitor system by using a 3-axis accelerometer in a smart phone [C]//Proceedings of the 16th International Symposium on Consumer Electronics. Harrisburg, PA, USA, 2012: 1-6.
- [7] DAI Jiangpeng, TENG Jin, BAI Xiaole, et al. Mobile phone based drunk driving detection [C]//Proceedings of the 4th International Conference on-NO Permissions, Pervasive Computing Technologies for Healthcare. Munich, Germany, 2010: 1-8.
- [8] PAEFGEN J, KEHR F, ZHAI Yudan, et al. Driving behavior analysis with smartphones: insights from a controlled field study [C]//Proceedings of the 11th Conference on Mobile and Ubiquitous Multimedia. New York, NY, USA, 2012: 408-414.
- [9] XU Lunbo, LI Shunyang, BIAN Kaigui, et al. Sober-Drive: A smartphone-assisted drowsy driving detection system [C]//Proceedings of International Conference on Computing, Networking and Communications. Honolulu, HI, USA, 2014: 398-402.
- [10] EREN H, MAKINIST S, AKIN E, et al. Estimating driving behavior by a smartphone [C]//Proceedings of IEEE Intelligent Vehicles Symposium. Alcalá de Henares, Spain, 2012: 234-239.
- [11] FAZEEN M, GOZICK B, DANTU R, et al. Safe driving using mobile phones [J]. IEEE transactions on intelligent transportation systems, 2012, 13(3): 1462-1468.
- [12] 李伟健, 林亚平, 叶松涛. 智能手机碰撞检测及在汽车事故自救中的应用 [J]. 计算机工程, 2011, 37(9): 245-247.
- LI Weijian, LIN Yaping, YE Songtao. Shock detection with smart mobile phone and its application in car accident self-rescue [J]. Computer engineering, 2011, 37(9): 245-247.
- [13] 赵龙, 闵昆龙, 韩玉杰. 基于智能手机群的车辆事故自救系统 [J]. 计算机系统应用, 2013, 22(2): 34-37.
- ZHAO Long, MIN Kunlong, HAN Yujie. Vehicle accident self-rescue system based on smart mobile phone groups [J]. Computer systems & applications, 2013, 22(2): 34-37.
- [14] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C]//Proceedings of IEEE International Joint Conference on Neural Networks. Budapest, Hungary, 2004, 2: 985-990.
- [15] CORTES C, VAPNIK V. Support-vector networks [J]. Machine learning, 1995, 20(3): 273-297.
- [16] FUNG G, MANGASARIAN O L. Proximal support vector machine classifier [C]//Proceedings of the 7th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA, 2001: 77-86.
- [17] HUANG Guangbin, DING Xiaojian, ZHOU Hongming. Optimization method based extreme learning machine for classification [J]. Neurocomputing, 2010, 74(1/2/3): 155-163.
- [18] 肖艳丽, 张振宇, 杨文忠. 移动数据的交通出行方式识别方法 [J]. 智能系统学报, 2014, 9(5): 536-543.
- XIAO Yanli, ZHANG Zhenyu, YANG Wenzhong. Research of the identification methods for transportation modes based on mobile data [J]. CAAI transactions on intelligent systems, 2014, 9(5): 536-543.

作者简介:



周后飞,男,1990年生,硕士研究生,主要研究方向为智能交通与设备。



刘华平,男,1976年生,副教授,主要研究方向为智能机器人。



石红星,男,1974年生,高级工程师,主要研究方向为路面材料、交通安全、智能交通,先后主持和参加多项省部级课题,获省级科技进步一等奖1项、三等奖2项,发表学术论文20余篇。