

DOI:10.20035/j.issn.1671-2668.2023.06.002

# 基于 STM32 和 MPU6050 的 AACN 系统模拟与 触发算法验证\*

赵中舒<sup>1</sup>, 田顺<sup>1,2</sup>, 颜黎明<sup>1</sup>

(1.长安大学汽车学院, 陕西 西安 710018; 2.长安大学未来交通学院, 陕西 西安 710018)

**摘要:** 车辆事故紧急呼叫装置(Advanced Automated Crash Notification, AACN)有助于实施事故后紧急救援,对减轻交通事故造成的人身伤害具有重要作用。文中使用 STM32 单片机和 MPU6050 模块搭建低成本车辆 AACN 模拟系统,配合电动试验小车构建 AACN 触发算法模拟验证系统,研究车辆 AACN 系统的事故识别触发算法。以正面碰撞和侧翻为研究对象,以采集的车辆关键参数为基础,采用长短期记忆(Long Short-Term Memory, LSTM)和双向长短期记忆(Bi-LSTM)神经网络辨识事故类型,结果显示, LSTM 和 Bi-LSTM 神经网络对正面碰撞的识别率分别为 96.41%、99.28%,对侧翻的识别率均在 99.00% 以上;使用基于速度变化原理的移动窗口算法进行实时事故检测对比验证,正面碰撞条件下触发正确率为 93.3%。综合表明,利用 MPU6050 采集的车辆姿态参数类型和精度对 AACN 系统计算与识别是足够的,神经网络算法识别精度较高,神经网络算法和移动窗口算法均能满足 AACN 模拟系统的事故识别要求。

**关键词:** 汽车;事故识别;事故紧急呼叫装置(AACN);STM32 单片机;MPU6050 模块;神经网络;移动窗口算法

中图分类号:U463.99

文献标志码:A

文章编号:1671-2668(2023)06-0009-07

如何减少交通事故、减轻事故伤害是当前社会关注的热点。车辆事故紧急呼叫装置(Advanced Automated Crash Notification, AACN)能及时提供车辆事故信息,起到减轻交通事故伤害的作用,受到大众和交通安全管理部门的关注<sup>[1]</sup>。相关研究表明, AACN 系统能降低 1.6%~3.3% 交通事故死亡率<sup>[2]</sup>。

AACN 系统触发算法的精确性直接关系到重大事故是否能被准确识别,是影响及时救援的关键因素。基于车辆速度信号进行触发算法识别是最基础的方法。AACN 系统可利用汽车上的速度传感器对车辆速度变化进行判断,当速度信号和加速度信号符合一定条件时,触发报警信号。另外,安全气囊一旦触发,可以认为已经发生了伤害程度较大的事故,而安全气囊大多是通过基于速度传感器的碰撞自动检测设备来实现触发,所以早期的 AACN 系统利用安全气囊的启动信号作为触发信号。近年来,倾向于设计一个独立于安全气囊触发信号的算法通道,以保证汽车发生碰撞后在安全气囊未正常

触发的情况下仍能发送呼救信号。徐叶雷等提出一种基于 MEMS 加速度计的新型车辆自动呼救系统,并运用全球定位系统(GPS)、嵌入式等技术,解决相对复杂的较常见的问题,更好地保护由于道路交通事故而严重受伤的驾驶员和乘客<sup>[3]</sup>。葛如海等使用移动窗口算法识别车辆事故,该算法对正面碰撞具有良好的适应性和灵敏性<sup>[4]</sup>。Xiao W. 等根据移动窗口内速度变化量对事故进行识别,该方法可快速识别碰撞事故且没有误触发现象<sup>[5]</sup>。李仲兴等采集 B 柱和 ECU 处车辆加速度信号,利用比功率法进行事故识别,其对 100% 刚性壁障碰撞事故的识别率达 82.5%<sup>[6]</sup>。杨林采用动态时间规整算法设计了车辆事故检测自动呼救系统<sup>[7]</sup>。苏忆等将比功率算法和移动窗积分算法进行融合设计车辆事故自动呼救系统,提高了系统的可靠性<sup>[8]</sup>。陆颖等分析 AACN 系统阈值对驾驶员伤情预测的影响,通过补偿算法提高了 AACN 系统伤情等级预测准确性<sup>[9]</sup>。Katagiri M. 等根据事故中车辆速度变化波形与事故

\* 基金项目:陕西省自然科学基金基础研究计划青年项目(2022JQ-007);中央高校基本科研业务费专项资金资助项目(300102220106)

类型的对应关系实现了事故类型在线识别<sup>[10]</sup>。以上研究设计的系统和算法存在整体识别率不高、算法较简单、成本较高等问题。本文基于 STM32 单片机和 MPU6050 模块设计 AACN 模拟系统采集试验数据,采用长短期记忆(Long Short-Term Memory, LSTM)和双向长短期记忆(Bi-LSTM)神经网络对常见事故状况(正面碰撞和侧翻)进行识别,并采用移动窗口算法进行对比验证。

## 1 AACN 模拟系统的硬件选择及数据采集

事故识别系统应设置合理的触发阈值。阈值设置过高,易产生漏触发现象;阈值设置过低,易产生误触发现象<sup>[11]</sup>。在汽车试验场内进行碰撞试验、侧翻试验、紧急刹车试验和颠簸路段试验,采集智能小车的车身加速度、角速度和角度信号,对采集信号进行移动窗口处理并确定合理的阈值。

### 1.1 AACN 硬件系统的选取

基于 STM32 单片机和 MPU6050 模块构建车辆事故模拟系统,主要硬件包括智能车、MPU6050 姿态数据读取模块、OLED 显示屏、锂电池、蜂鸣器等(见图 1)。

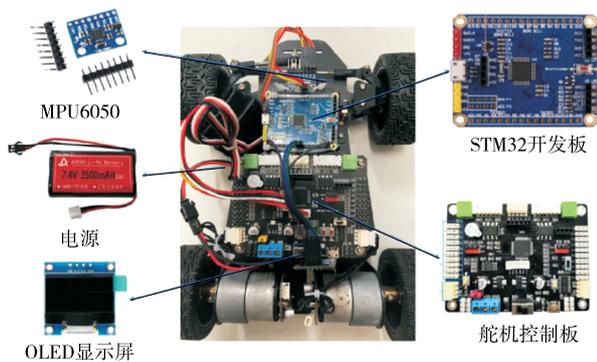


图 1 事故模拟系统的硬件

主控芯片选择对系统的硬件电路十分重要。应用于运动数据读取的单片机芯片有很多,如 ST 公司的 STM32 系列、TI 公司的 MSP430 系列、Atmel 公司的 AVR2560 系列等。STM32 作为一种较高端的微控制器,具有如下优点:布局精细,器件布置紧密;具有足够的硬件配置,包含看门狗、时钟控制、用于检测异常电压的检测器等;能够在 C 语言条件下实现在线编译、仿真和模块调试;能通过锁定 FLASH 引脚保证信息的完整程度和不被窃取,防止拉高引脚抹除芯片的内部信息。因此,选择 STM32 单片机作为 AACN 模拟系统的主控单元。

MPU6050 是全球首个整合性六轴惯性测量单元,包括三轴加速度计和三轴陀螺仪,其优点如下:相较于多组件方案,MPU6050 避免了组合陀螺仪与加速器时间轴之差的问题,减少了空间利用;成本低;MPU6050 支持 MPU 的 dmp 官方解算库,可以输出四元数、偏转角格式的数据;传感器的测量范围可控,可以精确跟踪快速和慢速的运动。因此,选择 MPU6050 模块采集数据。

### 1.2 数据采集

姿态数据读取模块主要由 MPU6050 陀螺仪、STM32 开发板构成,系统结构见图 2。控制器采用 STM32F103 作为中央处理器,其工作频率为 72 MHz,主要完成传感器数据采集、姿态解算(计算车身角度变化)、试验数据传送、试验结果处理等。MPU6050 水平固定于智能小车上,MPU6050 陀螺仪内置加速度计和陀螺仪,量程分别为  $\pm 16g$  和  $\pm 2000$  ( $^{\circ}$ )/s,加速度最高输出频率达 1 kHz,陀螺仪的最高输出频率达 8 kHz,可采集加速度、角加速度和角度。采样频率设置为 20 Hz,即 50 ms 完成一次数据采集。

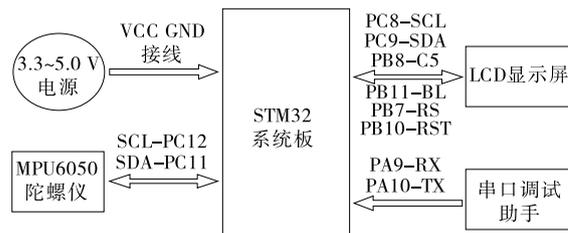


图 2 数据读取系统的结构

数据读取系统可直接读取加速度信号。须通过姿态解算获取角度信号,常见方法有四元数法、一阶互补算法和卡尔曼滤波算法,其中四元数法表达三维空间的旋转更直观,可以快速、精确地同时输出 3 个方向的角度变化。因此,采用四元数法进行姿态解算<sup>[12]</sup>。姿态解算方法如下:

(1) 初始化四元数,  $q_0 = 1, q_1 = q_2 = q_3 = 0$ 。

(2) 将角速度和周期信号代入龙格库塔公式[见式(1)]。

$$\begin{cases} q_0 = q_0 + (-q_1 g_x - q_2 g_y - q_3 g_z) \frac{T}{2} \\ q_1 = q_1 + (q_0 g_x + q_2 g_z - q_3 g_y) \frac{T}{2} \\ q_2 = q_2 + (q_0 g_y - q_1 g_z + q_3 g_x) \frac{T}{2} \\ q_3 = q_3 + (q_0 g_z + q_1 g_y - q_2 g_x) \frac{T}{2} \end{cases} \quad (1)$$

式中: $g_x$ 、 $g_y$ 、 $g_z$ 分别为 $x$ 、 $y$ 、 $z$ 轴的角速度信号; $T$ 为周期信号。

(3) 将四元数转化为角度[见式(2)]。

$$\begin{cases} \theta_y = \arcsin[2(q_1q_2 - q_1q_3)] \\ \theta_x = \arctan\left[\frac{2(q_0q_1 - q_2q_3)}{q_0^2 - q_1^2 - q_2^2 + q_3^2}\right] \\ \theta_z = \arctan\left[\frac{2(q_0q_3 + q_1q_2)}{q_0^2 + q_1^2 - q_2^2 - q_3^2}\right] \end{cases} \quad (2)$$

式中: $\theta_y$ 、 $\theta_x$ 、 $\theta_z$ 分别为俯仰角(车辆沿横向转动的角度)、滚转角(车辆沿纵向转动的角度)、偏航角(车辆沿垂向转动的角度)。

## 2 事故识别方法

### 2.1 基于神经网络算法的事故识别算法

循环神经网络能对数据中的序列信息及语义信息进行深度学习,被广泛应用于时间序列问题,比其他神经网络更适合处理车辆响应信号。采用两种典型的循环神经网络 LSTM 和 Bi-LSTM 进行对比分析。

#### 2.1.1 LSTM 和 Bi-LSTM 神经网络

LSTM 神经网络中,每一次循环都用到前一次循环的信息,输出状态受之前状态的影响,能更好地记忆长期的规律,被广泛应用于时间序列预测<sup>[13]</sup>。Bi-LSTM 神经网络由前向 LSTM 与后向 LSTM 组合而成并连接一个输出层,数据序列通过输入层进入隐含层,分别参与正向计算和反向计算,由输出层按照一定的权重融合正向和反向输出结果得到最终结果<sup>[14]</sup>。两种神经网络的结构见图 3。

#### 2.1.2 神经网络的参数设置

考虑正常行驶及发生正面碰撞、侧翻时车身加速度和角度的变化,选择发生显著变化的 4 个参数作为神经网络的输入,分别为纵向加速度  $a_x$ 、横向加速度  $a_y$ 、垂向加速度  $a_z$  和滚转角(车身坐标系中车辆沿纵向转动的角度  $\theta_x$ ),神经网络输入节点数  $n=4$ 。以上 4 个参数均可由事故模拟系统的数据读取模块测得。识别结果为正常行驶、正面碰撞、侧翻 3 种工况,输出层节点数  $d=3$ 。隐含层节点数根据经验及训练过程调整。

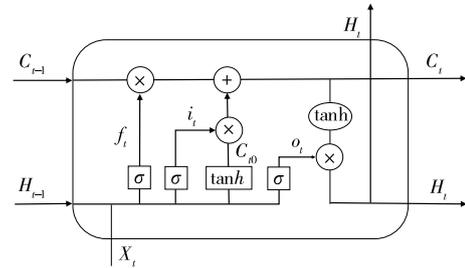
选用双曲线正切 sigmoid 函数作为隐含层的传递函数,表达式如下:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

事故类型识别属于分类问题。对于分类问题,

输出层函数采用 softmax 函数,表达式如下:

$$\sigma(x)_j = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}} \quad (j=1, \dots, k) \quad (4)$$



$C_{t-1}$ 为上一时刻的长期状态; $C_t$ 为当前时刻的单元状态; $C_t$ 为当前时刻的长期状态; $x_t$ 为当前时刻的输入; $H_{t-1}$ 为上一时刻的输出; $H_t$ 为当前时刻的输出; $i_t$ 、 $f_t$ 、 $o_t$ 分别为输入门、遗忘门、输出门; $\sigma$ (sigmoid)、 $\tanh$ 为激活函数

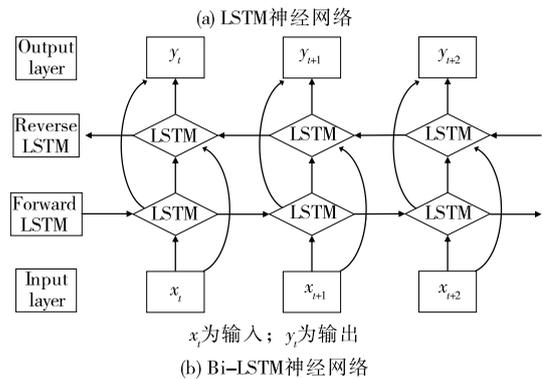


图 3 两种典型循环神经网络的结构

循环神经网络的训练算法采用 Adam,初始学习率设置为 0.005,验证集、测试集所占比例和最大迭代次数根据经验及训练过程调整。

#### 2.1.3 评价指标

事故类型识别属于分类问题,通常用混淆矩阵、精确率  $P$ 、召回率  $R$  及精确率和召回率的加权调和平均值  $F_1$  评估分类器的可信度。

混淆矩阵是衡量分类模型准确度的最基本、最直观、计算最简单的方法,其中:Positive(正例)代表事件发生,Negative(反例)代表事件未发生; $d_{TP}$ (真正例)表示真实值为正例,模型也认为是正例的事件; $d_{FP}$ (假正例)表示真实值是反例,模型认为是正例的事件,是统计学上的第一类错误; $d_{FN}$ (假反例)表示真实值是正例,模型认为是反例的事件,是统计学上的第二类错误; $d_{TN}$ (真反例)表示真实值是反例,模型也认为是反例的事件。混淆矩阵中  $d_{TP}$  和  $d_{TN}$  值越大,正确分类的数据越多,分类器的分类结果越理想。

精确率  $P$ 、召回率  $R$  和  $F_1$  的定义见式(5),其中精确率表示识别正例的精确度、召回率表示找到正例的精确度。精确率、召回率和  $F_1$  越大,分类器的分类效果越好,神经网络的识别效果越好。

$$\begin{aligned} P &= \frac{d_{TP}}{d_{TP} + d_{FP}} \\ R &= \frac{d_{TP}}{d_{TP} + d_{FN}} \\ F_1 &= \frac{2PR}{P + R} \end{aligned} \quad (5)$$

## 2.2 基于移动窗口算法的事故识别算法

移动窗口算法的原理源于速度变化量法<sup>[15]</sup>,该算法有两层阈值:第一层为门槛阈值,用于排除路面颠簸或车辆刹车的情况;第二层为触发阈值,用于识别车辆是否发生正面碰撞和侧翻。

如图4所示,对起始时刻附近区间的加速度信号进行积分, $[t_0 \sim t_n]$ 称为起始积分区间,区间长度 $\omega$ 称为窗宽,将该区间分成 $n$ 个小区间,利用梯形求积公式对 $n$ 个小区间进行积分求和得到该窗口的积分值。将移动窗口沿时间轴不断推进至下一窗口 $[t_1 \sim t_{n+1}]$ 、 $[t_2 \sim t_{n+2}]$ 、 $\dots$ 、 $[t_i \sim t_{i+n}]$ 。当某区间的加速度积分值超过所设定的阈值时,系统触发;否则,移动窗口继续向前推进。

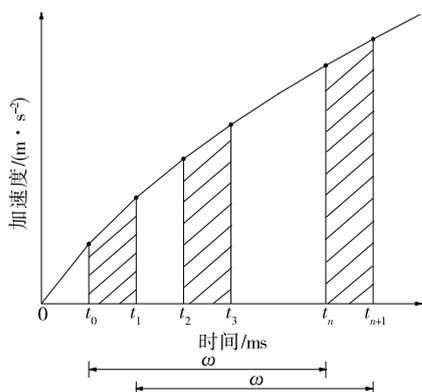


图4 移动窗口算法原理示意图

该方法运用移动窗口原理对车辆纵向加速度信号进行积分,判断车辆是否发生正面碰撞,表达式如下:

$$S(t, \omega) = \int_{t-\omega}^t a_x(t) dt \quad (6)$$

式中: $S(t, \omega)$ 为窗口 $\omega$ 内的速度变化量; $t$ 为时间; $\omega$ 为窗宽,可以根据采样频率进行选择; $a_x(t)$ 为纵向加速度。

移动窗口算法得到的速度变化曲线比单纯的加速度曲线更平滑,对碰撞的判断更准确,具有较强的

抗干扰能力。此外,该方法只与移动窗口内的速度变化量有关,不需要起始时刻,响应较迅速。

移动窗口算法的事故识别流程见图5。先判断车辆的纵向加速度 $a_x$ 是否大于门槛阈值,若大于门槛阈值,则将移动窗口内的积分值与所设定的触发阈值进行比较。若滚转角小于侧翻阈值,则移动窗口继续向前推进;若滚转角大于侧翻阈值,则判定车辆发生侧翻。若移动窗内的速度变化量 $\Delta v$ 小于触发阈值,则移动窗口继续向前推进;若 $\Delta v$ 大于触发阈值,则判定车辆发生正面碰撞。

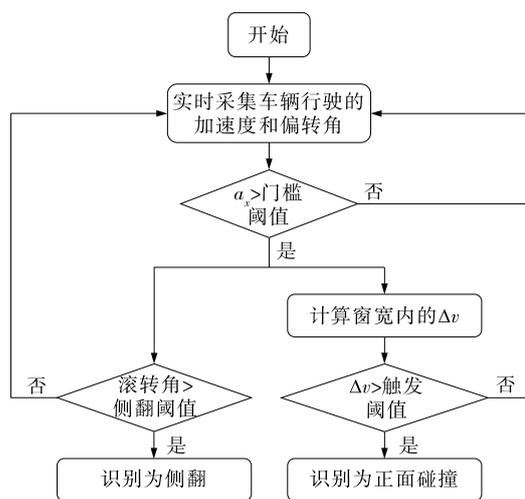


图5 事故识别系统流程

## 3 试验验证

### 3.1 神经网络的验证

神经网络的识别精度依赖于大量数据集。通过数据读取模块采集若干试验数据,经筛选,得到5 600组输入向量和输出向量,包括4 000组正常行驶数据、1 000组正面碰撞数据、600组侧翻数据。神经网络的学习样本节选见表1。

表1 学习样本节选

工况	输入向量 $\mathbf{P}$	理想输出向量 $\mathbf{T}$
正常行驶	[0.0 0.0 9.8 0.0]	[1 0 0]
正面碰撞	[20.0 10.0 15.0 0.0]	[0 1 0]
侧翻	[0.0 0.0 -9.8 180.0]	[0 0 1]

注:输入向量 $\mathbf{P}$ 中4个数据分别代表智能车辆纵向加速度 $a_x$ 、车辆横向加速度 $a_y$ 、车辆纵向加速度 $a_z$ ( $\text{m/s}^2$ )和滚转角 $\theta_x$ ( $^\circ$ );输出向量 $\mathbf{T}$ 中的数据代表输入向量的所属工况,[1 0 0]表示正常行驶工况,[0 1 0]表示车辆发生正面碰撞,[0 0 1]表示车辆发生侧翻。

根据经验及训练过程进行调整,取数据集的40%作为训练集、30%作为验证集、30%作为测试

集。综合训练时间和识别准确度,LSTM和Bi-LSTM的部分参数设置见表2。

表2 LSTM和Bi-LSTM的参数设置

神经网络类型	隐含层节点数/个	初始学习率	学习率下降期/次	学习率下降系数	训练算法	最大迭代次数/次
LSTM	21	0.003	150	0.8	Adam	200
Bi-LSTM	15	0.003	150	0.8	Adam	400

注:学习率下降期表示学习率开始下降的迭代次数。

两种神经网络的测试集识别结果见图6。其中:工况1代表正常行驶,工况2代表正面碰撞,工况3代表侧翻,以LSTM识别结果为例,(1,1)中,872表示预测工况为1、实际工况也为1的数据有872组,51.9%表示872组数据占有所有数据的比例;第4列、第4行分别表示各工况的召回率和精确率,如(4,1)表示实际工况为1的召回率为97%, (1,4)表示预测工况为1的精确率为99.9%, (4,4)表示正确识别的数据量占数据总量的97.9%。由图6可

知:实际工况为正常行驶时,LSTM和Bi-LSTM分别产生29组、2组误触发现象;发生正面碰撞时,LSTM和Bi-LSTM均有5组错误识别;发生侧翻时,两种神经网络均能准确识别。

为进一步验证两种神经网络模型的可靠性,计算测试集的精确率、召回率、 $F_1$ 、训练时间、均方根误差,结果见表3。由表3可知:Bi-LSTM的精确率、召回率、 $F_1$ 高于LSTM;LSTM的训练时间更短;LSTM和Bi-LSTM的均方根误差均低于0.06。

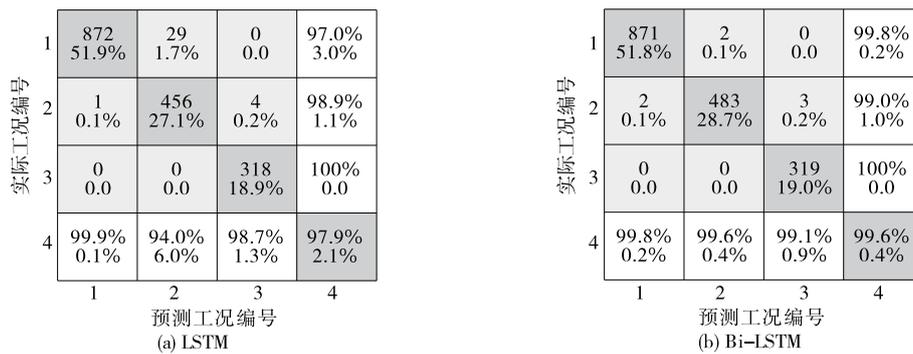


图6 测试集的识别结果(混淆矩阵)

表3 LSTM和Bi-LSTM测试集的评价结果

神经网络类型	运行工况	精确率	召回率	$F_1$	训练时间	均方根误差
LSTM	正常行驶	0.998 9	0.970 0	0.984 2		
	正面碰撞	0.940 2	0.989 2	0.964 1	9'36"	0.059
	侧翻	0.987 6	1.000 0	0.993 8		
Bi-LSTM	正常行驶	0.997 7	0.997 7	0.997 7		
	正面碰撞	0.995 9	0.989 8	0.992 8	17'35"	0.056
	侧翻	0.990 7	1.000 0	0.995 3		

综上,Bi-LSTM对事故发生的识别准确率更高,分类效果更好;LSTM的识别精确度略低于Bi-LSTM,但训练速度更快。可根据不同需求选取神经网络类型。

### 3.2 移动窗口算法的验证

#### 3.2.1 触发阈值的设置

通过试验验证移动窗口算法的可靠性。试验地点选择尽量平整的路面,以路肩作为正面碰撞试验

的前碰固定物、台阶作为侧翻试验地点。主要技术指标如下:采样频率为20 Hz,50 ms采集一次数据;速度为0~3 m/s;直线路段长度为20 m,侧翻路段长度为10 m;验证正面碰撞30组、紧急刹车及通过颠簸路段20组、侧翻10组。

##### 3.2.1.1 正面碰撞的触发阈值

门槛值根据经验而定且不宜设置过大,否则会影响车辆事故识别的灵敏度。根据智能小车紧急

刹车和通过颠簸路段的加速度数据,设置门槛阈值  $a_x = 3 \text{ m/s}^2$ ,即可排除车辆颠簸和紧急刹车的情况。

触发阈值根据移动窗口算法确定。先确定窗宽,窗宽选择过大会使检测时间变长,系统灵敏度过低;窗宽选择过小,可能受外部干扰而产生误触发现象。综合采样频率,选取窗宽为  $0.4 \text{ s}$ 。触发阈值的设置方法:1)通过数据读取模块采集若干组智能小车正面碰撞时的车身纵向加速度<sup>[16]</sup>,某组加速度曲线和样条插值曲线见图7。2)对采集的加速度以  $0.4 \text{ s}$ 的窗宽进行积分并选取速度变化量的最大值,加速度的积分值见图8。3)对比各组速度变化量的最大值,筛选出触发阈值  $\Delta v = 2.08 \text{ m/s}$ ,小车的速度变化量超过该值,则认为发生了碰撞。

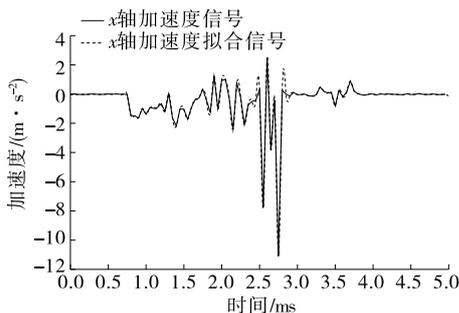


图7 发生正面碰撞时的加速度曲线

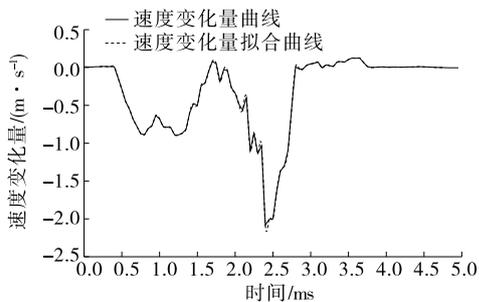


图8 发生正面碰撞时  $0.4 \text{ s}$ 窗宽内的积分值

### 3.2.1.2 侧翻的触发阈值

侧翻阈值可直接借助车辆沿纵向偏转的角度变化进行设置<sup>[17]</sup>。图9为数据读取模块采集的智能小车起步、加减速及发生侧翻时的滚转角  $\theta_x$ 。汽车侧翻是指汽车在行驶过程中绕其纵轴线转动  $90^\circ$ 或更大的角度,导致车身与地面接触的一种极其危险的侧向运动。选取侧翻触发阈值为  $90^\circ$ ,认为滚转角超过该角度时会发生侧翻。

### 3.2.2 验证结果分析

如图10所示,若未发生碰撞,屏幕显示3个方

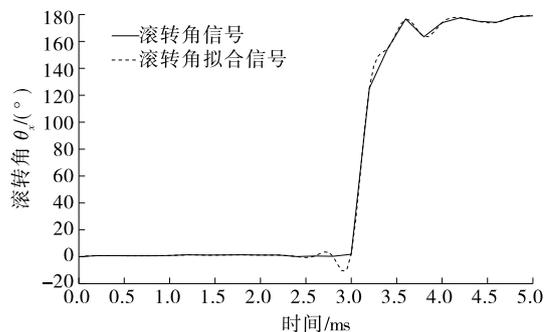


图9 侧翻下滚转角曲线

向的角度;若发生正面碰撞,屏幕显示 Crash;若发生侧翻,屏幕显示 Rollover。

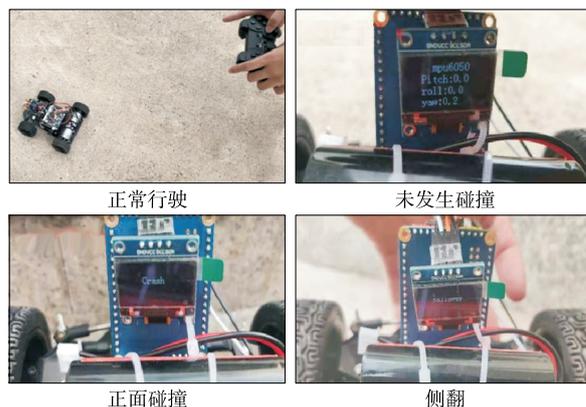


图10 试验验证

试验结果见表4。由表4可知:智能小车在正常行驶试验中误触发1次,在正面碰撞试验中未触发3次。智能小车在紧急刹车或通过颠簸路段时误触发次数较少,门槛阈值设置合理;事故识别的触发准确率为  $93.3\%$ ,触发阈值设置合理。

表4 移动窗口算法的验证结果 单位:次

工况	触发次数	未触发次数	试验次数
正常行驶	1	19	20
正面碰撞	27	3	30
侧翻	10	0	10

### 3.3 移动窗口算法与神经网络的适用性对比

对比移动窗口算法与神经网络的处理过程和实际效果,移动窗口算法搭配 AACN 系统具有较高的实用性和经济性,随着试验数据量的增加和阈值的不断修正,准确率提高,在低成本 AACN 系统中具有较好的应用前景;相较于移动窗口算法,神经网络算法具有很高的离线识别率,大量数据保证了该算法的可行性,未来在较高算力水准的处理器上可以

考虑更加复杂的工况进行在线识别。可综合考虑具体车型和成本等因素决定采用何种触发算法。

#### 4 结论

本文设计基于STM32和MPU6050的车辆碰撞事故识别模拟系统和基于神经网络的触发算法,并使用移动窗口算法进行对比验证,主要结论如下:1)采用三轴加速度和偏转角等车辆响应信号建立样本集,对比两种典型的循环神经网络,其中Bi-LSTM的测量精度更高,LSTM的运算速度更快,在样本数量充足的前提下,两种神经网络均能有效识别车辆事故类型。2)利用移动窗口算法设计智能小车在低速行驶工况下的触发阈值,验证正常行驶、正面碰撞和侧翻3种常见工况,事故的有效检测率达到93.3%,移动窗口算法能有效完成实时车辆事故类型检测。

由于时间和成本的限制,本文只进行了正常行驶、正面碰撞、侧翻3种工况的检测,未来应考虑侧面碰撞、偏置碰撞等复杂工况。另外,车辆高速事故识别还有待进一步验证;受采样率和窗宽的限制,具体车速条件下移动窗口算法的触发阈值有待进一步优化。

#### 参考文献:

- [1] BAHOUTH G, GRAYGO J, DIGGES K, et al. The benefits and tradeoffs for varied high-severity injury risk thresholds for advanced automatic crash notification systems[J]. *Traffic Injury Prevention*, 2014, 15(sup1): 134-140.
- [2] LEE E, WU J S, KANG T, et al. Estimate of mortality reduction with implementation of advanced automatic collision notification [J]. *Traffic Injury Prevention*, 2017, 18(sup1): 24-30.
- [3] 徐叶雷, 方勇. 基于MEMS加速度计的车用自动呼救系统[J]. *传感技术学报*, 2009, 22(6): 887-892.
- [4] 葛如海, 朱文婷, 臧绶. 基于改进移动窗算法的碰撞识别控制策略的研究[J]. *汽车工程*, 2011, 33(7): 590-593+622.

- [5] XIAO W, LI Z, CHEN W, et al. Trigger algorithm of vehicle automatic crash notification system[J]. *International Journal of Automotive Technology*, 2016, 17(2): 273-280.
- [6] 李仲兴, 马龙飞, 陆颖, 等. ACN系统加速度信号采集位置的比较分析[J]. *机械设计与制造*, 2018(11): 78-80+84.
- [7] 杨林. 车辆事故检测自动呼救系统研究与设计[D]. 广州: 华南理工大学, 2018.
- [8] 苏忆, 陆颖, 张玉辰. 双通道式车辆事故自动呼救系统的触发算法设计[J]. *机械设计与制造*, 2021(2): 71-74.
- [9] 陆颖, 殷越洲, 叶恒毅. 高级车辆事故自动呼救系统阈值对驾驶员伤情预测的影响[J]. *汽车技术*, 2020(3): 5-9.
- [10] KATAGIRI M, TSUBOUCHI H, UJIHASHI S, et al. Classification of crash pattern based on vehicle acceleration and prediction algorithm for occupant injury[J]. *International Journal of Automotive Engineering*, 2013, 4(1): 9-16.
- [11] 李仲兴, 刘爱松, 陆颖, 等. 车辆碰撞自动呼救系统触发算法设计[J]. *机械设计与制造*, 2018(5): 177-179.
- [12] 陈孟元, 谢义建, 陈跃东. 基于四元数改进型互补滤波的MEMS姿态解算[J]. *电子测量与仪器学报*, 2015, 29(9): 1391-1397.
- [13] 张心宇, 刘源, 宋佳凝. 基于LSTM神经网络的短期轨道预报[J]. *系统工程与电子技术*, 2022, 44(3): 939-947.
- [14] 李洋, 董红斌. 基于CNN和BiLSTM网络特征融合的文本情感分析[J]. *计算机应用*, 2018, 38(11): 3075-3080.
- [15] 陆颖, 叶恒毅, 魏凯. 车辆事故自动呼救系统碰撞识别方法抗干扰性研究[J]. *汽车技术*, 2018(6): 27-31.
- [16] 苏占领, 谭龙, 徐建勋, 等. 基于前车偏置场景的AEB系统性能测试与分析[J]. *公路与汽运*, 2023(1): 1-4+26.
- [17] 高轶男, 巩建强. 客车侧翻结构安全性能试验和优化研究[J]. *公路与汽运*, 2022(2): 1-4+7.

收稿日期: 2023-06-26