

文章编号: 1005-0523(2025)06-0091-10



冰雪环境下基于 CNN-BiGRU-MHA 的 汽车异常驾驶行为识别

裴玉龙, 范怡辰

(东北林业大学土木与交通学院, 黑龙江 哈尔滨 150000)

摘要: 为加强对冰雪环境下汽车异常驾驶行为的鉴别与检测, 提出了一种将 CNN-BiGRU 与 MHA 结合, 使用数据驱动的汽车异常驾驶行为识别方法。通过 LAIF 模型获取异常驾驶数据, 结合冰雪环境下车特点与数据特征, 构建异常驾驶行为指标, 表征急加速、急减速、急转弯、急变道、蛇形驾驶、打滑 6 种异常驾驶行为, 引入 ADASYN 平衡数据集。与其他模型进行对比分析, CNN-BiGRU-MHA 识别模型的准确率为 96.34%, 整体优于其他对比模型, 说明该模型能够有效识别冰雪环境下汽车异常驾驶行为, 为异常驾驶行为的预警提供了理论依据。

关键词: 智能交通; 异常驾驶行为识别; 多头注意力机制; 多标签分类; 冰雪环境

中图分类号: U268.6

文献标志码: A

本文引用格式: 裴玉龙, 范怡辰. 冰雪环境下基于 CNN-BiGRU-MHA 的汽车异常驾驶行为识别[J]. 华东交通大学学报, 2025, 42(6): 91-100.

Anomalous Driving Behavior Recognition of Vehicles Based on CNN-BiGRU-MHA in Ice and Snow Environments

Pei Yulong, Fan Yichen

(School of Civil Engineering and Transportation, Northeast Forestry University, Harbin 150000, China)

Abstract: To enhance the monitoring and detection of abnormal driving behavior of vehicles in snow and ice conditions, this paper proposes a data-driven method for identifying abnormal driving behaviors by integrating multi-channel CNN-BiGRU with MHA. Abnormal driving data are obtained by LAIF model, combined with driving characteristics and data features under ice and snow environments, abnormal driving behavior indicators are constructed to characterize 6 kinds of abnormal driving behavior, namely rapid acceleration, rapid deceleration, rapid turning, rapid lane change, serpentine driving and skidding, and the ADASYN is introduced. The model proposed in this paper is compared and analysed with other models. The CNN-BiGRU-MHA detection model has an overall accuracy of 96.34%, which is better than other detection models indicating that the model can effectively detect the abnormal driving behavior of cars in ice and snow environments, and provides a theoretical basis for early warning of abnormal driving behavior.

Key words: intelligent transportation; abnormal driving behavior recognition; multi-head attention mechanism; multi-label classification; ice and snow environments

收稿日期: 2024-09-05

基金项目: 黑龙江省重点研发项目(JD22A014)

Citation format: PEI Y L, FAN Y C. Anomalous driving behavior recognition of vehicles based on CNN-BiGRU-MHA in ice and snow environments[J]. Journal of East China Jiaotong University, 2025, 42(6): 91–100.

汽车异常驾驶行为是导致交通事故发生的重要原因之一^[1],准确识别异常驾驶行为可以降低交通事故发生率,提升交通安全^[2]。这里所述的驾驶包括人工驾驶和各种等级下的自动驾驶。异常驾驶行为识别不仅能够增强驾驶员的规范驾驶意识,而且是自动驾驶理论的重要组成部分,自动驾驶车辆最重要的是需要平稳,不能有急转弯、急加速等。

目前研究大多使用视频或图像数据识别异常驾驶行为,神经网络具有强大的非线性映射能力和自学习能力,被广泛应用于驾驶行为识别领域。Huang等^[3]提出了3种新的深度学习融合模型,实现了基于视频的异常驾驶行为检测任务。Xiong等^[4]提出了一种用于视频监控异常驾驶行为检测的非线性稀疏重构的方法,在停车标志数据集和停车场数据集两个数据集上测试了异常检测方法的性能。赵建东等^[5]基于时间序列符号化算法与多尺度卷积神经网络模型提出一种组合模型TSA-MCNN,用于识别重点营运车辆异常驾驶行为。吴建清等^[6]综合考虑货车操纵数据、驾驶员眼动数据和心电数据,构建重载货车危险驾驶行为数据集,采用随机森林分类模型识别危险驾驶行为。惠飞等^[7]提出一种基于双向长短记忆网络(BiLSTM)及全连接神经网络(FC)的拓展神经网络检测模型。Jia等^[8]提出一种基于长短期记忆网络和卷积神经网络的识别模型(LSTM-CNN),通过对真实车辆驾驶数据的统计分析,检测出极端加减速点。Zhang等^[9]提出了一个端到端深度学习框架来自动提取驾驶行为的特征,对时间特征进行建模,捕捉显著结构特征。

现有研究普遍只考虑了正常驾驶环境,未考虑在冰雪环境下的驾驶情况,汽车在冰雪路面上行驶时附着力大大降低,出现异常驾驶行为的概率增加。

为了解决上述问题,本文使用汽车运行状态数据,对冰雪环境下汽车异常驾驶行为识别问题。通过卷积神经网络(CNN)^[10]从序列的长期趋势中捕捉非线性和空间关系,双向门控循环单元(BiGRU)^[11]处理时间序列问题,并引入多头注意力机制(MHA)^[12]来学习不同参数的重要性,提出了CNN-BiGRU-MHA

组合模型识别冰雪环境下汽车的异常驾驶行为。

1 数据分析

1.1 数据集介绍

本文选取加拿大冰雪条件下自动驾驶数据集(CADC)^[13]作为异常驾驶行为识别研究的数据基础,数据集中的所有样本均在降雪或积雪的环境下采集,未包含非冬季或无冰雪条件的数据,其数据类型如表1所示。

表1 CADC数据类型
Tab.1 CADC data types

数据名称	数据类型
Time/ms	时间
Acceleration/(m/s ²)	加速度
Steering wheel angle/(°)	方向盘角度
Speed/(m/s)	车速
Wheel angular/(rad/s)	车轮角速度
Lateral acceleration/(m/s ²)	横向加速度

1.2 数据预处理

原始数据质量对研究结果有至关重要的影响。本数据集使用的传感器以及通信设备在冰雪环境下运行过程会受到各方面的因素影响,可能导致数据质量出现问题,所以需对数据进行预处理来提高数据质量。

1) 缺失数据处理。

$$y_i = \frac{y_{i-1} + y_{i-2} + \cdots + y_{i-p}}{p} \quad (1)$$

式中: y_i 为第 i 个数据,这个数据是缺失的; y_{i-1}, \cdots, y_{i-p} 为缺失数据前的正常数据; p 为数据采用长度。

2) 异常或噪声数据处理。

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (2)$$

式中: \bar{y} 为每个序列的算术平均值; n 为序列的长度。

3) 重采样。本文主要使用从 Dataspeed ROS 消息中转换而来的汽车控制数据以及 NovAtel IMU 传感器数据。因为数据采集频率不同,所以需要对数据重采样,使其输出频率保持一致。考虑到异常

驾驶行为识别模型的实时处理性能和主要原始数据的采集频率,本文选择的数据频率为20 Hz。

2 异常驾驶行为特征分析

2.1 构建异常驾驶行为指标

采用显著性分析对各指标与异常驾驶行为之间的关系进行判断,删除冗余指标,最终留下与异常驾驶行为状态显著相关的指标。急加速、急减速选取纵向加速度作为行为指标,急转弯、急变道和蛇形驾驶选取横向加速度作为行为指标,打滑通过车轮角速度和速度计算得到的滑移率来表示。本研究构建的冰雪环境下异常驾驶指标如图1所示。




图1 异常驾驶行为指标

Fig.1 Abnormal driving behavior indicators

2.2 基于混合方法的异常驾驶数据提取

本文针对多维时间序列,使用自动编码器和孤立森林结合的反馈学习(LAIF)驾驶数据异常点检测模型^[14],其流程如图2所示。

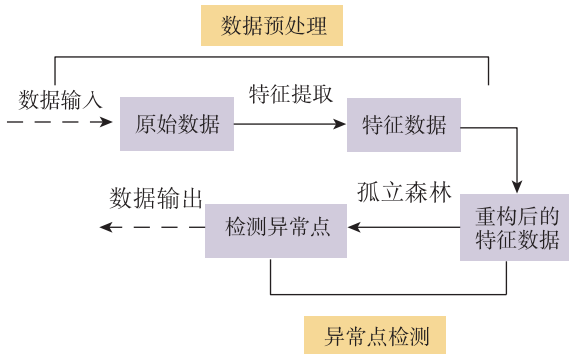


图2 LAIF模型流程

Fig.2 LAIF model process

2.2.1 特征提取

引入滑动窗口提取异常驾驶行为数据波动特征,由于异常驾驶行为时间持续2~6 s,此处设定滑动窗口为4 s。从时间序列数据的起始点开始,每4 s取一个窗口,设定窗口的步长为1 s,即每次移动窗

口时,只前进1 s或2 s,会与上一个窗口有部分重叠。原始数据使用矩阵 D 来表示,计算式为

$$D = \{D_1, D_2, \dots, D_{t-1}, D_t\}$$

式中: t 为异常驾驶行为持续时间, s ; D_t 为 t 时刻驾驶行为的各个参数值; $D_t = \{d_t^1, d_t^2, \dots, d_t^{j-1}, d_t^j\}$, d_t^j 为 t 时刻第 j 项数据值。

2.2.2 数据重构

异常数据特征通常与其前一时间步内的数据变化息息相关,所以这里选择的自动编码器是具有处理时序特征功能的 Encoder-Decoder 模型^[15],该模型可以不改变数据的结构。将输入的数据序列转换成有确定长度的矩阵向量,再将向量转化为输出数据序列,编码过程是将输入序列 x 转化为一个固定长度的向量 c 。解码过程是将之前生成的固定向量转化成输出序列 y ,根据学习后的数据特征重构数据,使汽车状态数据的异常特征变化更明显。

2.2.3 异常点检测

孤立森林是一种快速的离群点检测算法,适用于连续数据的异常点检测,基于孤立森林^[16]的异常点检测算法较传统的聚类算法等具有更高的鲁棒性。

根据异常驾驶行为指标体系,对比同一时刻相关指标的异常点。由于打滑指标存在空值,所以这里展现了除打滑后剩余5种异常驾驶行为的3个指标。将方向盘角度和横向加速度在同一时段内的异常分数以及加速度的异常分数以折线图的方式进行展现,将数据中的异常点用红色圆点进行标注,结果如图3所示。

2.3 异常驾驶行为分类

正常驾驶时汽车运行状态数据一般在稳定区间内小幅度波动,当出现一些错误操作时会导致汽车异常行驶,运行数据在较短的时间内有突变的过程,根据以上异常检测结果,并结合冰雪环境下轮胎与路面的附着能力很低,制动距离延长,将异常驾驶行为分为6类。正常驾驶与异常驾驶行为的区别如图4所示。

1) 急加速。图4(a)橙线和蓝线分别代表急加速行为和正常加速行为,急加速表现为短时间内纵向加速度明显增大,而正常加速的加速度曲线增长趋势较平缓,在小范围内波动。

2) 急减速。图4(b)橙线和蓝线分别代表急减




图3 变化分数
Fig.3 Change scores

速行为和正常减速行为,急减速行为表现为纵向减速度急剧增加,从而产生极端减速值,而正常的减速行为为更平稳并在一段时间内保持较小的值。

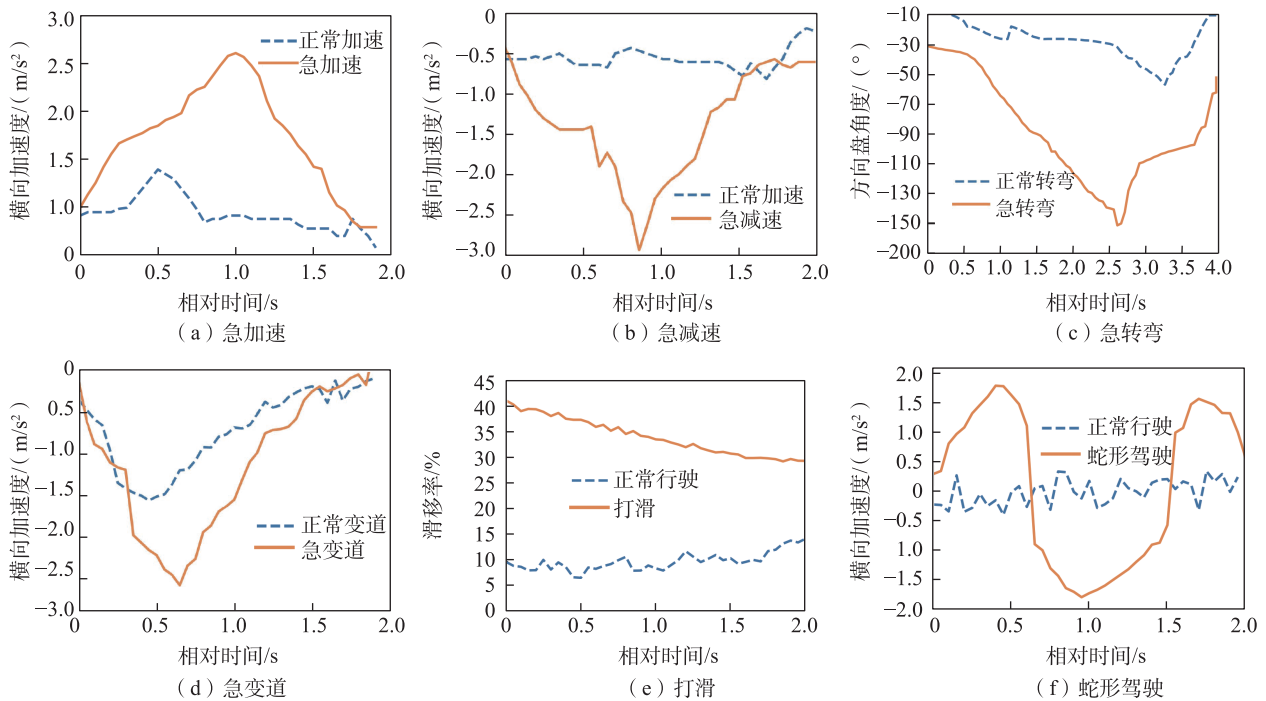


图4 异常驾驶行为特征分析

Fig.5 Analysis of abnormal driving behavior characteristics

3) 急转弯。转弯行为的指标和换道行为类似,同样体现在横向加速度的大小差异上,不同的是,转弯行为的持续时间以及加速度的峰值大于换道行为,并且急转弯时,方向盘角度会急剧变化,从图4(c)可以看出,橙线表示急转弯行为,方向盘角度在短时间内变化急剧,正常转弯行为方向盘角度曲线变化平缓。

4) 急变道。图4(d)中橙线表示急变道行为,以较大横向加速度进行变道操作,蓝线代表正常变道驾驶行为,横向加速度变化缓慢并且峰值较小。

5) 打滑。本文选取的表征打滑的指标是滑移率,引用汽车理论上的原理:汽车滑移率控制在20%左右时,轮胎有较大的制动力,同时保证有足够的横向力,通过计算4个车轮的滑移率,判断是否打滑。汽车滑移率 S 的计算式为

$$S = \frac{(v - rw)}{v} \times 100\% \quad (3)$$

式中: v 为汽车车速; r 为车轮半径; w 为车轮轮速。从图4(e)可以看出发生打滑时,汽车滑移率会超过20%。

6) 蛇形驾驶。图4(f)中橙线是蛇形驾驶行为,横向加速度出现较大波动,蓝线表示正常驾驶行为横向加速度曲线在很小范围内波动。

2.4 自适应合成采样

数据集中异常驾驶数据为少数类,导致各样本间分布不均衡,为解决数据不平衡问题,针对CADC数据集中少数样本量,采用自适应合成采样算法(ADASYN)^[17]平衡数据集。

Step 1: 计算少数类需要合成的样本数量 G , 表达式为

$$G = (m_1 - m_s) \times \beta \quad (4)$$

式中: m_1 为多数类样本数量,即正常驾驶行为的数量; m_s 为少数类样本数量,即异常驾驶行为的数量, $\beta \in [0, 1]$ 是用于在生成合成样本后所需的平衡级别参数, $\beta = 1$, 采样后正负比例为 1:1。

Step 2: 计算近邻中多数类占比, 表达式为

$$r_i = \frac{\Delta_i}{k} \quad (5)$$

式中: Δ_i 为 b_i 的 k 近邻中多数类占比; b_i 是少数类样本中第 i 个数据样本, $i \in [1, m_s]$ 。

Step 3: 对 r_i 进行标准化 \hat{r}_i 处理, 表达式为

$$\hat{r}_i = \frac{r_i}{\sum_{i=1}^{m_s} r_i} \quad (6)$$

Step 4: 计算异常驾驶行为样本需要生成新样本的数目 g_i , 表达式为

$$g_i = r_i \times G \quad (7)$$

Step 5: 基于 SMOTE 算法生成合成样本, 表达式为

$$s_i = b_i + (b_{zi} - b_i) \times \lambda \quad (8)$$

式中: s_i 为本研究中最终的合成样本; b_{zi} 为 b_i 的 k 近邻中随机选取的一个少数类样本; $\lambda \in [0, 1]$ 。

2.5 建立异常驾驶行为数据集

通过异常点检测,在原始数据中找到异常驾驶行为所在位置,并利用滑动窗口截取相应的异常驾驶行为数据段,寻找多名熟悉时间序列驾驶数据和驾驶行为的研究人员来进行异常驾驶行为片段的筛选工作,为冰雪环境下汽车状态数据标注驾驶行为标签,完成异常驾驶行为样本数据集构建。本文共 242 个数据段建立数据集,其中包括急加速 20 段、急减速 27 段、急转弯 18 段、急变道 15 段、打滑 18 段、蛇形驾驶 4 段,正常驾驶 160 段,由于样本不平衡,本文使用 ADASYN 算法平衡数据集,以下模型训练中使用的数据集是均衡后的数据集。

3 基于 CNN-BiGRU-MHA 的异常驾驶行为识别方法

3.1 异常驾驶行为识别方法结构

本文的识别方法结构如图 5 所示,模型分为数据集构建和识别模型两大部分。

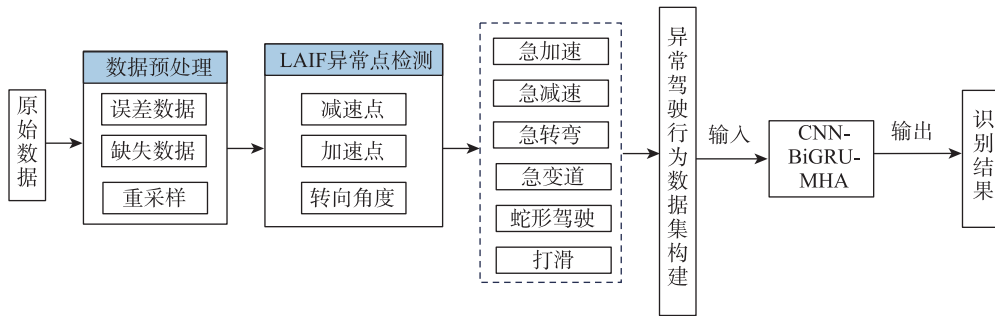


图5 异常驾驶行为识别方法结构

Fig.5 Structure of abnormal driving behavior recognition method

3.2 算法原理

3.2.1 CNN

为进一步提取输入层汽车状态数据的潜在特征,挖掘数据之间的潜在规律,引入CNN对时序数据进行处理,CNN采用局部连接和权值共享的方式进行连接,可以通过卷积和池化的操作对数据的内部特征进行有效提取^[18]。本文CNN包括卷积层和

池化层。首先将输入数据的维度进行变换适应一维卷积层的输入要求,然后在前向传播中,使用ReLU激活函数对卷积后的结果进行非线性变换,卷积操作后,再次调整维度以适应池化层的输入要求,最后进行最大池化操作。

为了减少网络结构参数和过拟合问题,利用池化层捕捉代表性特征^[19]。CNN运算描述为

$$c_u^l = f\left(\sum_{o=1}^0 c_o^{l-1} F_{ou}^l + b_u^l\right) \quad (9)$$

$$C_{out} = \{c_1, c_2, \dots, c_u\} \quad (10)$$

$$p = \{p_1, p_2, \dots, p_u\} = \text{Maxpooling}(C_{out}) \quad (11)$$

式中: b_u^l 为第 l 层的偏置; c_u^l 为第 l 层中第 u 通道的特征映射; F_{ou}^l 为第 l 层的滤波器, o 和 u 分别为第 $l-1$ 和第 l 层的通道; o, u 为卷积层输出通道数, $j \in [1, u]$; $f(\cdot)$ 为激活函数; C_{out} 为整个特征图; p 为多个特征, p_i 为对 C_i 进行的最大池化操作 $\text{Maxpooling}(\cdot)$ 。

3.2.2 BiGRU层

门控循环单元(GRU)作为一种改进的循环神经网络(RNN)^[20],可以解决传统RNN的梯度消失或爆炸问题。GRU的每一层都有许多循环链接存储块,这些块由更新门和重置门两个门单元组成。GRU的传统单向传输方式适用于处理依赖历史信息的模型,但是实际驾驶中的异常情况不仅由过去的驾驶行为决定,还与未来时刻的信息相关。针对这一特性,本文引入双向门控循环单元(BiGRU),其结构如图6所示,BiGRU有两个隐藏的GRU层分别处理正向和反向的序列,可结合前后两个时间方向的汽车状态数据信息,来提高异常驾驶行为识别的准确性。

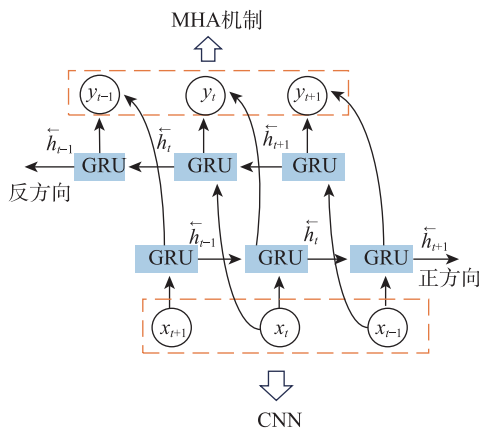


图6 双向GRU

Fig. 6 Bidirectional GRU

BiGRU接受CNN中的输出数据作为输入,学习时序前后汽车状态数据的复杂关联关系,深度挖掘隐藏在时间序列中的特征信息,并将各个时刻的隐层状态输出至多头注意力机制,隐层状态输出

$$\vec{h}_t = F_{GRU}(q_t, \vec{h}_{t-1})$$

$$\vec{h}_t = B_{GRU}(q_t, \vec{h}_{t-1})$$

$$h_t = \alpha_t \vec{h}_t \oplus \beta_t \vec{h}_t \quad (12)$$

式中: F_{GRU} , B_{GRU} 分别为正向和反向网络结构; α_t , β_t 分别为 t 时刻BiGRU所对应的前向隐层状态 \vec{h}_t 和反向隐层状态 \vec{h}_t ; q_t 为输入数据; \vec{h}_t 和 \vec{h}_t 分别是 t 时刻前向和后向GRU的状态。

3.2.3 MHA

不是所有的汽车状态数据对于异常驾驶行为识别都有着同样的贡献,所以为了自动对异常驾驶行为数据指标权重进行调整,引入MHA来对双向门控循环神经网络的隐层状态输出赋予不同的权重。

分别对每个自注意机制进行单独计算,然后将每个自注意力机制的输出进行连接^[21],得到最后输出

$$A_h = \text{softmax}\left(\frac{Q_h K_h^T}{\sqrt{d_k}}\right) V_h \quad (13)$$

$$A(x) = \text{Concat}(A_1, A_2, \dots, A_h) W \quad (14)$$

式中: $h=1, 2, \dots, H$; A_h 为第 h 个头的注意力输出; Q_h 为第 h 个头的查询向量; V_h 为第 h 个头的值向量; d_k 为键向量的维度; K_h^T 为第 h 个头的键向量的转置; $\text{softmax}(\cdot)$ 用于产生注意力权重; $A(x)$ 为 h 个头的注意力输出相加操作 $\text{Concat}(\cdot)$; W 为权重向量,最后结果由全连接层映射,得到最终识别结果。

3.3 CNN-BiGRU-MHA组合识别模型构建

CNN-BiGRU-MHA架构主要包括输入层、卷积层、最大池化层、多头注意力机制、全连接层、输出层。通过CNN捕捉数据中的局部特征关系,将其输出作为BiGRU的输入,BiGRU的作用是提取时间特征,将结果输入到注意力模块,MHA层通过自学习为数据中每个传感器数据分配权重,突出更重要数据的效果,忽略不重要数据。完全连接层包括2个隐藏层,其神经节点与前一层的神经节点相关,在完全连接层中使用激活函数ReLU来拟合提取的特征。为了减少模型过拟合的问题,在卷积层中使用了Dropout^[22],通过损失函数和优化器^[23]不断更新和迭代模型参数。

4 验证分析

4.1 损失函数

本文使用了多标签分类损失函数,计算式为

$$\text{Loss}(d, e) = \sum_j \frac{\max(0, 1 - (d \| e \|_j - d \| i \|))}{d.\text{size}(0)} \quad (15)$$

式中: $\text{Loss}(\cdot)$ 为损失函数; d 为神经网络输出; e 为真实类别标签; $d.\text{size}(0)$ 为返回 d 的第一维大小。模型损失最小时, 模型完成训练过程, 然后将测试数据集输入 CNN-BiGRU-MHA 模型, 评估训练后的模型。

4.2 评价指标

为了进一步评估不同方法对异常驾驶行为识别的有效性, 在实验中选择了3个评估指标。

1) 加权 F_1 分数计算式为

$$F_1 = \sum_i 2\omega_i \frac{PR}{P+R} \quad (16)$$

式中: i 为类别指数; $\omega_i = n_i/N$, 为第 i 类样本的比例; N 为样本总数。精确率 P 的计算式为

$$P = \frac{P_T}{P_T + P_F} \quad (17)$$

召回率 R 的计算式为

$$R = \frac{P_T}{P_T + N_F} \quad (18)$$

其中 P_T 、 N_T 、 P_F 和 N_F 分别代表真阳性、真阴性、假阳性和假阴性样本。

2) 准确率 A 的计算式为

$$A = \frac{P_T + N_T}{P_T + P_F + N_T + N_F} \quad (19)$$

3) 接受者操作特性(ROC)曲线通过真阳性率和假阳性率作为横坐标来描绘分类器在不同阈值下的性能, 真阳性率 R_{TP} 计算式如下

$$R_{TP} = \frac{P_T}{P_T + N_F} \quad (20)$$

假阳性率 R_{FP} 计算式为

$$R_{FP} = \frac{P_F}{P_F + N_T} \quad (21)$$

4.3 CNN-BiGRU-MHA 测试结果

该算法是在 Tensorflow 框架中构建的, 使用了 Python3.7 编译算法, 为了证明所提出的方法的有效性, 使用 CNN-BiGRU-MHA 模型对7种驾驶行为进行了测试, 包括急加速、急减速、急变道、急转弯、蛇形驾驶、打滑和正常驾驶, CNN-BiGRU-MHA 的模型配置如表2所示。

图7中蓝线和橙线分别表示训练过程和测试过程的识别率变化曲线、损失函数。训练数据集的准确率平均接近97%, 这表明 CNN-BiGRU-MHA 模型在识别异常驾驶行为方面性能较好。迭代25次

表2 模型配置

Tab.2 Model configuration

层名	参数	说明
Num_heads	8	注意力机制头数
GRU-layers	1	门控循环单元层数
Batch size	64	训练一次的样本数量
Dropout	0.2	10%的神经元被丢弃
Learning_rate	0.001	学习率
Hidden_size	128	隐藏层单元数量
Input_size	12	输入数据维度
Out_size	7	输出数据维度





图7 CNN-BiGRU-MHA 训练过程
Fig.7 Training process of CNN-BiGRU-MHA

之后, 训练准确率达到90%, 这表明 CNN-BiGRU-MHA 的收敛速度较快且训练过程稳定, 可以看出所提出的 CNN-BiGRU-MHA 在测试数据集上也实现了高评估指标。

4.4 其他方法的比较

在实验过程中, 所有模型均使用相同数据集,

为了保证模型的泛化,本研究采用了5折交叉验证^[24],将总数据样本分成5个部分,其中4个部分用于训练模型,1个部分用于验证。将数据集输入到现有方法中,包括CNN、随机森林、支持向量机(SVM)。选择类别之间的准确率、AUC、测试集的 F_1 分数来评估本文提出的模型和其他模型的性能,所有模型在Adam优化器下进行训练,网络对比如表3所示。

由表3可以直观看出,CNN-BiGRU-MHA模型识别驾驶行为的准确率高出CNN、SVM、随机森林模型。SVM模型对7种驾驶行为的 P 、 R 、 F_1

分数都比较低,无法正确区分6种异常驾驶行为,相比于SVM,CNN、随机森林的识别效果有所改善,但依旧误判、漏判情况还是较多,CNN-BiGRU-MHA模型对于正常驾驶、急加速、急减速、急转弯、急变道都有较好的识别效果,对于蛇形驾驶、打滑识别结果稍显不足,但仍高于其他识别方法。macro为宏平均,对每种类别分别计算 P 和 R ,再对其取算术平均值,得到macro- P ,macro- R ,macro- F_1 ;micro为微平均,将混淆矩阵对应元素进行平均,基于平均值计算micro- R ,micro- P ,micro- F_1 。

表3 网络对比结果
Tab.3 Network comparison results

模型	类别	A	P	micro- P	macro- P	R	micro- R	macro- R	F_1	micro- F_1	macro- F_1
CNN	0		0.39			0.70			0.49		
	1		0.53			0.31			0.38		
	2		0.54			0.35			0.34		
	3	0.56	0.82	0.55	0.57	0.80	0.55	0.57	0.81	0.52	0.54
	4		0.71			0.49			0.58		
	5		0.69			0.53			0.61		
	6		0.29			0.76			0.41		
SVM	0		0.24			0.29			0.26		
	1		0.35			0.29			0.32		
	2		0.64			0.18			0.28		
	3	0.39	0.48	0.48	0.45	0.39	0.38	0.34	0.43	0.36	0.34
	4		0.24			0.64			0.35		
	5		0.23			0.34			0.27		
	6		0.92			0.48			0.63		
随机森林	0		0.65			0.69			0.69		
	1		0.64			0.62			0.64		
	2		0.70			0.67			0.69		
	3	0.77	0.91	0.77	0.79	0.88	0.76	0.78	0.91	0.78	0.79
	4		0.90			0.93			0.92		
	5		0.85			0.80			0.84		
	6		0.85			0.83			0.90		
CNN-BiGRU-MHA	0		0.95			0.83			0.88		
	1		0.71			0.96			0.82		
	2		0.93			0.98			0.96		
	3	0.96	0.99	0.90	0.91	0.99	0.90	0.92	0.99	0.90	0.91
	4		0.92			0.99			0.95		
	5		0.97			0.77			0.86		
	6		0.91			0.90			0.90		

5 结论

1) 对数据进行预处理后,利用异常驾驶行为数据提取与人工标注结合的方法截取异常驾驶行为片段,利用自适应合成采样算法平衡数据集,使样本分布更均匀,在一定程度上降低了人工标注的主观性。

2) 针对传统模型无法学习不同传感器数据对异常驾驶行为的重要程度,在门控循环单元后引入MHA提取时间序列关系与不同传感器数据之间的关联关系,经验证本文所提出的模型识别准确率明显有所提高。

3) 通过与随机森林、CNN、SVM模型进行对比实验,本文提出的CNN-BiGRU-MHA模型3个评价指标效果均优于其他模型,识别精度高、泛化性强,可以有效识别出6种异常驾驶行为,提高道路行车安全性。

4) 尽管本研究基于加拿大的驾驶数据,但使用的特征和模型具有较好的通用性。然而,不同国家和地区的交通规则、驾驶习惯等因素可能影响模型的适用性。因此,未来的工作将包括在中国不同地区采集更多的数据,对模型进行调整。

参考文献:

- [1] WANG D Y, LIU Q Y, MA L, et al. Road traffic accident severity analysis: a census-based study in China[J]. *Journal of Safety Research*, 2019, 70: 135-147.
- [2] 贾硕, 惠飞, 马峻岩, 等. 商用车异常驾驶行为检测算法研究[J]. *公路交通科技*, 2017, 34(S2): 29-36.
JIA S, HUI F, MA J Y, et al. Study on detection algorithm of abnormal driving behavior of commercial vehicles[J]. *Journal of Highway and Transportation Research and Development*, 2017, 34(S2): 29-36.
- [3] HUANG W, LIU X, LUO M Y, et al. Video-based abnormal driving behavior detection via deep learning fusions[J]. *IEEE Access*, 2019, 7: 64571-64582.
- [4] XIONG Q H, ZHOU S J, CHEN Q S. Abnormal driving behavior detection based on kernelization-sparse representation in video surveillance[J]. *Multimedia Tools and Applications*, 2022, 81(4): 4585-4601.
- [5] 赵建东, 陈溱, 焦彦利, 等. 重点营运车辆的异常驾驶行为识别研究[J]. *交通运输系统工程与信息*, 2022, 22(1): 282-291.
ZHAO J D, CHEN Q, JIAO Y L, et al. Recognition of abnormal driving behavior of key commercial vehicles[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2022, 22(1): 282-291.
- [6] 吴建清, 张子毅, 王钰博, 等. 考虑多模态数据的重载货车危险驾驶行为识别方法[J]. *交通运输系统工程与信息*, 2024, 24(2): 63-75.
WU J Q, ZHANG Z Y, WANG Y B, et al. Method for identifying dangerous driving behaviors in heavy-duty trucks based on multi-modal data[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2024, 24(2): 63-75.
- [7] 惠飞, 郭静, 贾硕, 等. 基于双向长短记忆网络的异常驾驶行为检测[J]. *计算机工程与应用*, 2020, 56(24): 116-122.
HUI F, GUO J, JIA S, et al. Detection of abnormal driving behavior based on BiLSTM[J]. *Computer Engineering and Applications*, 2020, 56(24): 116-122.
- [8] JIA S, HUI F, LI S N, et al. Long short-term memory and convolutional neural network for abnormal driving behaviour recognition[J]. *IET Intelligent Transport Systems*, 2020, 14(5): 306-312.
- [9] ZHANG J, WU Z C, LI F, et al. Attention-based convolutional and recurrent neural networks for driving behavior recognition using smartphone sensor data[J]. *IEEE Access*, 2019, 7: 148031-148046.
- [10] HE X, XU L, ZHANG Z. Driving behaviour characterisation by using phase-space reconstruction and pre-trained convolutional neural network[J]. *IET Intelligent Transport Systems*, 2019, 13(7): 1173-1180.
- [11] CHEN D Q, YAN X D, LIU X B, et al. A multiscale-grid-based stacked bidirectional GRU neural network model for predicting traffic speeds of urban expressways[J]. *IEEE Access*, 2020, 9: 1321-1337.
- [12] 王婷婷, 王振豪, 李方, 等. 基于增强多头注意力机制的Optuna-BiGRU测井岩性识别[J]. *地球科学与环境学报*, 2024, 46(1): 127-142.
WANG T T, WANG Z H, LI F, et al. Lithology identification in Optuna-BiGRU logging based on enhanced multi-head attention mechanism[J]. *Journal of Earth Sciences and Environment*, 2024, 46(1): 127-142.
- [13] PITROPOV M, GARCIA D E, REBELLO J, et al. Canadian adverse driving conditions dataset[J]. *The International Journal of Robotics Research*, 2021, 40(4/5): 681-690.
- [14] 刘静. 多维时间序列异常点检测方法及其应用研究[D]. 天津: 中国民航大学, 2020.
LIU J. Research on outlier detection in multidimensional time series and its application[D]. Tianjin: Civil Aviation

- University of China, 2020.
- [15] HAO S Y, LEE D H, ZHAO D. Sequence to sequence learning with attention mechanism for short-term passenger flow prediction in large-scale metro system[J]. Transportation Research Part C: Emerging Technologies, 2019, 107: 287-300.
- [16] YANG N, ZHANG Z K, YANG J H, et al. Mineralized-anomaly identification based on convolutional sparse autoencoder network and isolated forest[J]. Natural Resources Research, 2023, 32(1): 1-18.
- [17] PARK H, KIM H. AR-ADASYN: angle radius-adaptive synthetic data generation approach for imbalanced learning[J]. Statistics and Computing, 2024, 34(5): 166.
- [18] 杨晓文, 张健, 况立群, 等. 融合 CNN-BiGRU 和注意力机制的网络入侵检测模型[J]. 信息安全研究, 2024, 10(3): 202-208.
- YANG X W, ZHANG J, KUANG L Q, et al. A network intrusion detection model integrating CNN-BiGRU and attention mechanism[J]. Journal of Information Security Research, 2024, 10(3): 202-208.
- [19] 裴莹玲, 罗晖, 张诗慧, 等. 基于改进 Faster R-CNN 的高铁扣件检测算法[J]. 华东交通大学学报, 2023, 40(1): 75-81.
- PEI Y L, LUO H, ZHANG S H, et al. High-speed railway fastener detection algorithm based on improved faster R-CNN[J]. Journal of East China Jiaotong University, 2023, 40(1): 75-81.
- [20] MIN K, KIM D, PARK J, et al. RNN-based path prediction of obstacle vehicles with deep ensemble[J]. IEEE Transactions on Vehicular Technology, 2019, 68(10): 10252-10256.
- [21] 徐文翔, 王俊骅, 傅挺. 基于注意力机制及分层网络的危险驾驶行为预测方法[J]. 同济大学学报(自然科学版), 2022, 50(5): 722-730.
- XU W X, WANG J H, FU T. Aggressive driving behavior prediction method based on attention mechanism and hierarchical network[J]. Journal of Tongji University (Natural Science), 2022, 50(5): 722-730.
- [22] ZHANG Y, HE Y Y, ZHANG L K. Recognition method of abnormal driving behavior using the bidirectional gated recurrent unit and convolutional neural network[J]. Physica A: Statistical Mechanics and Its Applications, 2023, 609: 128317.
- [23] CHIBANE F, BENAMMAR A, DRAI R, et al. Parameter estimation for ultrasonics echoes using an weighted mean of vectors optimizer[J]. Russian Journal of Nondestructive Testing, 2023, 59(10): 1027-1038.
- [24] ABOU E Z E, MOUSANNIF H, AL MOATASSIME H, et al. The application of machine learning techniques for driving behavior analysis: a conceptual framework and a systematic literature review[J]. Engineering Applications of Artificial Intelligence, 2020, 87: 103312.



通信作者:裴玉龙(1962—),男,教授,博士,研究方向为智能交通与管理。E-mail:peiyulong@nefu.edu.cn。

(责任编辑:姜红贵)