

中文引用格式:程方明,胡佳萌,苟蕊. 基于深度学习的车辆行驶风险与转向意图预测模型[J]. 中国安全科学学报, 2026, 36(4): 94-102.

英文引用格式:Cheng Fangming, Hu Jiameng, Gou Rui. A driving risk and steering intention prediction model based on deep learning[J]. China Safety Science Journal, 2026, 36(4): 94-102.

基于深度学习的车辆行驶风险与转向意图预测模型*

程方明^{1,2}教授, 胡佳萌^{1,2}, 苟蕊^{1,2}

(1 西安科技大学 安全科学与工程学院, 陕西 西安 710054;

2 西安市城市公共安全与消防救援重点实验室, 陕西 西安 710054)

中图分类号:X951

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2026.04.1070

基金项目:教育部人文社会科学研究规划基金资助(23YJAZH016);秦创原城市公共安全智能感知与应急救援“科学家+工程师”队伍项目(2024QCY-KXJ-170)。

【摘要】 针对传统模型存在多维时序特征挖掘能力有限以及类别不平衡问题,提出一种基于类别平衡损失(CB)机制-非对称损失(ASL)机制-TimesNet的多任务行驶风险预测模型。利用滑动时间窗口提取多维时序特征,提升风险等级标注的客观性与细致性,并基于这些特征构建前向、后向、侧向碰撞风险及转向意图4类标签;在模型构建方面,融入TimesNet网络,有效捕捉多维时序特征的周期性变化与动态演化特性,增强复杂驾驶场景下时序信息的建模能力;结合CB与ASL机制设计损失函数,提升模型在类别不平衡条件下的预测性能。结果表明:提出的CB-ASL-TimesNet模型在行驶风险与转向意图预测任务中的平均准确率达到0.9086,与传统机器学习模型CatBoost相比提升16%,较主流时间序列模型门控循环单元(GRU)提升5.8%,验证了所提模型在提升预测性能方面的显著有效性。

【关键词】 深度学习; 行驶风险与转向意图; 类别不平衡; TimesNet; 损失函数

A driving risk and steering intention prediction model based on deep learning

Cheng Fangming^{1,2}, Hu Jiameng^{1,2}, Gou Rui^{1,2}

(1 School of Safety Science and Engineering, Xi'an University of Science and Technology,

Xi'an Shaanxi 710054, China; 2 Xi'an Key Laboratory of Urban Public Safety and Fire

Rescue, Xi'an Shaanxi 710054, China)

Abstract: To address the limitations of traditional models in mining multi-dimensional temporal features and handling class imbalance, A multi-task driving risk prediction model based on Class Balance loss (CB)-Asymmetric Loss (ASL)-TimesNet and is proposed. A sliding time window was employed to extract multi-dimensional temporal features, improving the objectivity and granularity of risk level labeling. Based on these features, four types of labels were constructed: forward collision risk, rear collision risk, lateral collision risk, and steering intention. In terms of model design, the TimesNet architecture was

incorporated to effectively capture periodic variations and dynamic evolution in multi-dimensional temporal features, thereby enhancing the modeling capability of temporal information in complex driving scenarios. Meanwhile, a hybrid loss function integrating CB and ASL was devised to improve prediction performance under class-imbalanced conditions. Experimental results demonstrate that the proposed CB-ASL-TimesNet model achieves an average accuracy of 0.908 6 in driving risk and steering intention prediction tasks. Compared with the traditional machine learning model CatBoost, the proposed approach yields a 16% improvement, and it outperforms the mainstream time-series model Gate Recurrent Unit (GRU) by 5.8%, verifying the significant effectiveness of the proposed model in enhancing prediction performance.

Keywords: deep learning; driving risk and steering intention; category imbalance; TimesNet; loss function

0 引言

随着城市化进程的加快,机动车保有量持续攀升,道路交通安全问题日益严峻。据世界卫生组织统计,全球每年约有 119 万人死于道路交通事故^[1],严重威胁社会经济发展和公共安全。为有效降低交通事故发生率,提升道路交通安全水平,行驶风险与转向意图预测逐渐成为智能交通系统^[2]与车辆主动安全领域的重要研究方向。

早期行驶风险预测方法主要依赖基于先验知识的模型^[3-4]和机器学习模型^[5-8],尽管取得一定进展,但传统方法在特征建模、时序特征挖掘和多任务预测方面存在不足,未能充分捕捉交通系统的动态演化特性。近年来,深度学习因优越的特征自动提取、时序建模与非线性建模能力,逐渐成为行驶风险与意图预测的研究热点。例如:赵海涛等^[9]基于车联网边缘计算的事故风险预测方法,显著提升了行驶风险预测精度;高镇海等^[10]构建了基于长短时记忆神经网络 (Long Short-term Memory Networks, LSTM) 的多模态轨迹预测模型,增强了自动驾驶车辆的意图预测能力;Jin Zhixiong 等^[11]结合卷积神经网络 (Convolutional Neural Network, CNN) 与深度神经网络 (Deep Neural Networks, DNN),开发了高性能风险预测系统;Lee 等^[12]基于自然驾驶数据提出的深度混合模型,在风险分级预测中表现出良好的稳健性与适应性。然而,许多研究仍未解决自然驾驶数据中的类别不平衡问题,严重影响了少数类样本的预测精度。为解决这一问题,Yu Rongjie 等^[13]引入焦点损失来改善 CNN 分类效果,王博文等^[14]结合过采样技术和极致梯度提升 (eXtreme Gradient Boosting, XGBoost),通过上采样与扰动增强了少数类样本的代表性;Wang Ke 等^[15]则采用自动化机器学习与贝叶斯优化,调节采样率、类别权重与损失函

数,提升了高风险驾驶员的识别能力。上述研究主要关注行驶风险预测,较少涉及行驶意图识别及二者的联合建模。然而,行驶风险与转向意图密切相关,联合预测有助于全面刻画驾驶行为特性,提升潜在风险的预判能力,为自动驾驶系统提供更具前瞻性的决策依据^[16]。此外,现有方法普遍存在行驶风险划分粗糙、标注主观性强和类别不平衡显著等问题,限制了模型性能和应用效果。

鉴于此,笔者将行驶风险细化为多种碰撞风险类型,准确反映当前决策后果的即时评估,同时联合转向意图预测,表征驾驶者未来决策趋向及其对交通环境的主观判断;围绕风险标签构建、多任务预测模型设计及损失函数优化等关键环节,为智能交通系统的安全保障提供理论支持。

1 自然驾驶数据预处理

1.1 数据来源与特征构造

采用 UAH-DriveSet 公开数据集进行试验^[17]。该数据集由西班牙阿尔卡拉大学研究团队采集,旨在支持驾驶行为分析与车辆安全相关研究。采集的数据类型超过 30 种,基本涵盖了自然驾驶安全研究所需的主要信息。

为全面表征自然驾驶环境下驾驶行为与道路交互过程中的多源动态特征,基于 UAH-DriveSet 数据集,依据数据来源与功能属性,将原始特征数据划分为物理相关因素、道路相关因素和交互相关因素 3 大类。各类因素下包含的特征参数、物理单位及数据类型见表 1。鉴于原始特征数据采样频率不一致、取值范围差异较大及变量类型多样,针对不同数据类型采用相应的数据处理方法:连续数值型变量通过 Z-score 标准化处理,消除量纲影响;区间评分型变量采用归一化映射至 0~1 区间;离散类别型变

量采用独热编码。确保数值化过程不引入虚假顺序信息,从而实现多源异构数据的统一规范,为后续模型训练提供可靠数据基础。

表 1 数据结构
Table 1 Data structure

因素	原始特征参数及单位	描述	数据类型
物理 相关 因素	X 轴加速度/(m/s^2)	车辆垂向加速度	连续型
	Y 轴加速度/(m/s^2)	车辆横向加速度	连续型
	Z 轴加速度/(m/s^2)	车辆纵向加速度	连续型
	横滚角/($^\circ$)	—	连续型
	俯仰角/($^\circ$)	—	连续型
	偏航角/($^\circ$)	—	连续型
	速度/(km/h)	—	连续型
	高度(海拔)/ m	—	连续型
	航向角/($^\circ$)	—	连续型
	航向变化量/($^\circ$)	—	连续型
	加速评分	0~100,越高表示越平稳	区间型
	刹车评分	0~100,越高表示刹车越平滑	区间型
	转弯评分	0~100,越高表示转弯越平稳	区间型
	漂移评分	0~100,越高表示越少漂移行为	区间型
	车辆与车道中心的偏移/ m	—	连续型
道路 相关 因素	汽车相对于车道曲率的角度/($^\circ$)	—	连续型
	道路宽度/ m	—	连续型
	车道检测算法状态	-1=校准中, 0=初始化, 1=未检测到, 2=检测到/运行中	离散型
	当前道路限速/(km/h)	—	连续型
	获取的最高限速的可靠性	0=未知, 1=可靠, 2=使用先前获取的最高限速, 3=根据道路类型估计	离散型
	道路类型	高速公路、主干道、二级公路等	离散型
	当前道路的车道数	—	连续型
	估计的当前车道	1=右车道, 2=最左侧车道, 3=从右往左数第二个左侧车道等	离散型
	GPS 纬度	GPS 坐标	连续型
	GPS 经度	GPS 坐标	连续型
	OSM 回答查询的延迟时间/ s	—	连续型
	垂直精度/ m	—	连续型
	水平精度/ m	—	连续型
	位置状态	状态码	离散型
	车道状态	状态码	离散型
交互 相关 因素	超速评分	0~100,越高表示超速行为越少	区间型
	与前车距离/ m	—	连续型
	与前车碰撞时间/ s	—	连续型
	检测到的车辆数	—	连续型
	跟车评分	0~100,反映与前车时距控制情况	区间型
	变道类型	+表示右向变道, -表示左向变道	离散型
	变道评分	0~100,越高表示越少急剧横向变道	区间型

注:全球定位系统(Global Positioning System,GPS);开放街道地图(Open Street Map,OSM)。

1.2 基于多特征数据的标签生成方法

为识别行驶风险与转向意图,需构建一个具有良好代表性与区分度的标签体系。基于预测窗口中提供的多特征数据,设计4项多任务预测标签:前向

碰撞风险、后向碰撞风险、侧向碰撞风险以及转向意图预测,其中每个标签均划分为3个类别。

其中,前向、后向和侧向碰撞风险3个标签均基于预测时间窗口内提取的多维动态特征,采用

K-means 聚类算法确定其类别划分。具体所选特征及聚类结果见表 2。在不同聚类中心设定下,样本分布呈现明显差异,当类别数过多时,部分类别的样本量过少,可能导致模型在训练过程中难以有效识别少数类。综合考虑样本分布特性,前向、后向和侧向

碰撞风险标签最终划分为 3 个相对稳定的类别,即高风险、中风险和低风险。而对于转向意图标签,根据预测窗口内的变道类型信息,判断是否存在明确的转向行为。进而将该标签划分为前进、左转、右转 3 类,用以反映驾驶员在不同驾驶场景中的潜在转向意图。

表 2 不同类型行驶风险与转向意图的判定依据与等级划分标准

Table 2 Criteria and classification standards for different types of driving risks and steering intentions			
标签	标签设计依据	标签设计方法	类别样本数 ($K=2/K=3/K=4$)
前向碰撞风险	Z 轴加速度、与前车距离、碰撞时间、速度、超速评分、跟车评分、加速评分	K-means 聚类	$K=2:6\ 033/22\ 293$ $K=3:4\ 397/1\ 602/22\ 327$ $K=4:587/1\ 157/1\ 423/25\ 168$
后向碰撞风险	Z 轴加速度、速度、刹车评分、加速评分		$K=2:5\ 401/22\ 925$ $K=3:3\ 555/3\ 453/21\ 318$ $K=4:875/1\ 828/4\ 551/21\ 072$
侧向碰撞风险	Y 轴加速度、漂移评分、变道评分、转弯评分、车道偏离估计		$K=2:7\ 457/20\ 869$ $K=3:6\ 097/5\ 732/16\ 497$ $K=4:663/6\ 197/1\ 447/20\ 019$
转向意图预测	变道类型(左变道、右变道、直行)	行为驱动规则	1 615/1 092/25 619

基于 60 s 的观测窗口及未来 60 s 的预测窗口设计特征和标签,共获得 28 362 个有效样本,确保了数据规模的充足性与多样性。根据表 2 中各标签的类别数据分布明显发现,所构建的多任务预测标签均存在不同程度的类别不平衡现象,尤其是转向意图预测标签,其类别间分布差异较为显著,该不平衡性为模型训练带来一定挑战。

2 行驶风险与转向意图预测模型

2.1 基于 TimesNet 的预测模型

传统机器学习模型通常依赖于单时刻的静态特征作为输入,难以有效捕捉行驶过程中的动态时序演化特性。相比之下,深度学习方法能够直接将时间序列作为模型输入,利用多特征的动态变化信息进行建模,突破了传统预测模型在时序建模方面的局限性。近年来,提出的 TimesNet 模型^[18]作为一种新型时间序列预测网络,展现了出色的时序特征建模能力。自提出以来,TimesNet 已在安全风险评估等领域得到应用^[19]。在该模型基础上进行针对性地结构修改与优化,使其能够适应车辆行驶风险与转向意图预测的多标签、多分类任务。

基于 TimesNet 构建多标签三分类模型,其结构如图 1 所示。模型输入为 $[B,T,31]$ 的张量,其中, B 表示批量大小, T 表示时间序列长度,31 表示每个时间步的特征数据维度。核心的 TimesBlock 模块堆叠构成模型主体。每个 TimesBlock 通过多周期

分析和卷积结构,统一表征时间序列多周期动态模式及其关联特性。为完成多任务多分类预测,设计 4 个独立的分类头,分别对应转向意图、后向碰撞风险、前向碰撞风险和侧向碰撞风险。每个分类头输出 3 类预测结果,即 $[B,3]$ 的向量。每个向量包含 3 个元素,分别对应任务的 3 类预测概率。通过这种结构,模型能够在统一的特征表示基础上,同时完成 4 个任务的三分类预测,实现多任务协同学习。

2.2 CB-ASL 损失函数

在行驶风险预测任务中,各任务均属于多类别预测问题,且普遍存在类别不平衡现象。传统交叉熵损失函数(Cross-Entropy Loss,CE)易偏向多数类,导致模型对少数类样本的识别能力不足,影响整体预测性能。针对该问题,结合类别平衡损失(Class-Balanced Loss,CB)^[20]机制与非对称损失(Asymmetric Loss,ASL)^[21]机制构建 CB-ASL 联合损失函数,以有效提升模型对少数类的敏感性,缓解类别不平衡带来的性能下降。

CB 依据各类别样本数量动态分配权重,从而提升模型对稀有类别的关注度,第 c 类类别权重 w_c 计算方式为:

$$w_c = \frac{1 - \beta}{1 - \beta^{N_c}}$$

(1)

式中: β 为控制权重衰减速度的超参数, $\beta \in [0, 1)$,通常取值接近 1; N_c 为第 c 类的样本数量。

此外,ASL 针对正负样本数量极度不平衡问题,




图 1 TimesNet 结构

Fig. 1 TimesNet structure

通过调节正负类损失项权重,增强正类样本的优化力度,减弱易分类负类对损失的主导作用。其定义为:

$$L_{A(y,p)} = \begin{cases} -(1-p)^{\gamma^+} \ln(p), & y = 1 \\ -p^{\gamma^-} \ln(1-p), & y = 0 \end{cases} \quad (2)$$

式中: $L_A(y,p)$ 为基于 ASL 的损失值; A 为损失函数; y 为标签值; p 为预测概率; γ^+ 和 γ^- 分别为正负类的调节因子,用以控制难以分类样本损失的放大程度。该机制通过弱化高置信度负类样本的损失权重,同时保持对正类样本的标准调节,从而提升模型对关键少数类的学习能力。

将上述 2 种机制融合,统一兼顾类别不平衡与正负类不均衡问题,表达式如下:

$$L_{CA} = \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^c w_c \cdot L_A(y_{i,c}, p_{i,c}) \quad (3)$$

式中: L_{CA} 为 CB-ASL 损失值; CA (CB-ASL) 为损失函数; $L_A(y_{i,c}, p_{i,c})$ 为第 i 个样本在第 c 类下的 ASL 损失值; N 为样本数量; c 为样本类别。

3 多任务预测模型的试验与分析

3.1 试验设置与评估方法

时间窗口长度设定为 60,即使用过去 60 个时

间步的特征进行行驶风险与转向意图的多任务预测。

为验证文中所提 TimesNet 模型及其改进模型的优越性与有效性,将其试验结果与多种对比模型比较。对比模型包括类别型特征提升法 (Categorical Boosting, CatBoost), 深度学习方法中基于全连接网络的反向传播 (Back Propagation, BP) 模型、CNN 模型、基于循环神经网络的门控循环单元 (Gate Recurrent Unit, GRU) 模型、基于注意力机制的神经网络模型 Transformer (TR) 以及 TimeMixer 模型。基于 TimesNet 改进的模型包括融合 CB Loss 函数与 ASL 函数的 CB-TimesNet 模型、ASL-TimesNet 模型和 CB-ASL-TimesNet 模型。鉴于模型性能受多种超参数设置的影响,需要优化各模型的超参数。在有限的超参数组合范围内,采用 10 折交叉验证方法寻优,从而获得各模型的最优参数及对应性能。TimesNet 模型及损失函数的超参数范围见表 3。

模型在单任务下的性能评价采用准确率、召回率、精确率和 F_1 值 4 项指标。各指标及部分计算式见表 4。为全面评估模型在多任务场景下的整体预测能力,引入 4 项任务的平均指标,即对 4 项任务的

准确率、召回率、精确率和 F_1 值分别取平均,从而综合反映模型的整体性能,并体现其在多任务条件下的全局适应性。

表 3 TimesNet 模型及损失函数的超参数范围

Table 3 Hyperparameter ranges for TimesNet model and loss function

模块	超参数	范围	说明
TimesNet	d_model	64,128,256	模型内部特征维度
	e_layers	1,2	TimesBlock 堆叠层数,即 TimesBlock 模块数量
	d_ff	64,128,256	前馈网络隐藏维度
	num_kernels	3,5	卷积核数量,用于提取不同周期特征
	top_k	3,4,5	FFT 提取主导频率时保留的最大频率数量
损失函数	γ^-	2,3	对易分类的负类样本的惩罚程度
	γ^+	0	对易分类的正类样本的惩罚程度
	t	0.05	非对称概率截断阈值
	β	0.999,0.999 2,0.999 4,0.999 6	CB Loss 中的类别平衡因子

注:快速傅里叶变换(Fast Fourier Transform,FFT)。

表 4 性能指标及含义

Table 4 Performance indicators and their meanings

指标	指标含义	评估依据	评估标准
准确率 A	预测正确的样本占总样本的比例	$(TP+TN)/(TP+TN+FP+FN)$	值越高越好
精确率 R	预测为正例的样本中真实正例的比例	$TP/(TP+FP)$	值越高越好
召回率 P	真正例被预测为正例的比例	$TP/(TP+FN)$	值越高越好
F_1 值	调和平均的 R 和 P	$\frac{2 \times R \times P}{(R + P)}$	越接近 1 越好

注:TP 为真正例(True Positive,TP);FP 为假正例(False Positive,FP);TN 为真反例(True Negative,TN);FN 为假反例(False Negative,FN)。

3.2 模型对比分析

采用交叉熵作为损失函数,同时联合预测转向意图、前向碰撞风险、后向碰撞风险和侧向碰撞风险 4 项任务,各模型性能指标对比见表 5。

表 5 行驶风险与意图预测模型性能指标对比

Table 5 Comparison of performance metrics for driving risk and steering intention prediction models

模型	4 项任务平均指标			
	A	R	P	F_1
CatBoost	0.782 9	0.782 9	0.790 6	0.753 6
BP	0.787 1	0.787 1	0.795 7	0.784 8
CNN	0.825 6	0.825 6	0.837 9	0.825 5
GRU	0.858 9	0.858 9	0.852 0	0.847 7
Transformer	0.851 6	0.851 6	0.865 6	0.851 9
TimeMixer	0.861 1	0.861 1	0.858 5	0.856 1
TimesNet	0.876 4	0.876 4	0.870 9	0.868 1

统计各模型在每个任务的每个类别上的 F_1 值、精确率、召回率和准确率指标值,并汇总同一指标下所有任务各个类别的表现,绘制箱型图(图 2),直观展示模型在各个类别的性能分布特性和中位数水平,突出模型间性能差异与稳定性。结合表 5 和

图 2,多种模型在多任务预测中的性能存在显著差异,TimesNet 模型在多项指标中表现出最佳性能,其箱型图显示中位数较高、上下四分位距较窄且离散性较小,表明该模型在多任务、多类别预测场景中具备较强的准确性和稳定性。

相比之下,传统机器学习模型 CatBoost 在各项指标上的表现相对较弱,说明其预测结果的稳定性和整体效果不足,且容易受到类别分布差异的影响。综上,TimesNet 模型在多任务多类别预测中展现了优异的综合性能,而传统机器学习方法在稳定性和准确性方面存在一定不足,验证了深度学习方法在复杂动态预测问题中的有效性。值得注意的是,在召回率、精确率和 F_1 值指标下,各模型在不同任务和类别的表现呈现明显两极分化,箱线图的上下须分别接近 0 和 1。其主要原因在于:①类别分布严重不平衡,少数类别样本量极小,使指标对错误预测高度敏感,导致小类别指标接近 0;②多数类别样本量大,模型预测几乎完全正确,使指标接近 1。由此形成两极分化的分布,箱线图上下须分别靠近 0 和 1。相比之下,准确率指标受多数类样本主导,其分布更集中,箱线图上下须不会出现如此极端的情况。




图2 各模型在不同指标下的多任务性能箱型图

Fig. 2 Box plots of multi-task performance for each model under different metrics

3.3 损失函数改进分析

为验证 CB Loss 与 ASL 在处理类别不平衡任务中的有效性,在同一基础模型 TimesNet 上进行对比试验。TimesNet 原始模型采用标准交叉熵损失训练,作为基线。在此基础上分别使用 CB Loss、ASL 以及 CB-ASL 联合损失进行训练,保持模型结构不变,仅替换损失函数以评估其对模型性能的影响。

从表 6 和图 3 来看,引入 CB Loss 后,CB-TimesNet 在 4 项任务平均指标均有所提升,图 3 表明类别平衡损失能够提升少数类样本的关注度,改善提升精确率指标。然而,在实际预测中,CB-TimesNet 也导致部分易分类样本的负样本数量增加,使得 CB-TimesNet 的多任务性能箱图中,召回率下限明显降低。

表 6 不同模型的性能指标

Table 6 Performance metrics for different models				
模型	4 项任务平均指标			
	A	R	P	F ₁
TimesNet	0.876 4	0.876 4	0.870 9	0.868 1
CB-TimesNet	0.867 0	0.867 0	0.867 2	0.872 5
ASL-TimesNet	0.889 2	0.889 2	0.880 3	0.881 2
CB-ASL-TimesNet	0.908 6	0.908 6	0.895 5	0.897 1

引入 ASL 后,ASL-TimesNet 在 4 项平均指标上

进一步优于 CB-TimesNet,由图 3 表明:该方法平衡了类别不平衡问题和过度关注负样本问题。相较 CB Loss,ASL 更好地平衡了正负样本间的损失权重,有效降低了对易分类负样本的过拟合倾向,避免负样本数量无效增加导致召回率指标降低问题。




图3 各模型在不同指标下的多任务性能箱型图

Fig. 3 Box plots of multi-task performance for each model under different metrics

CB Loss 与 ASL 联合应用的 CB-ASL-TimesNet 在所有指标上均取得最佳性能。其中,4 项任务平均准确率达到 0.908 6。据图 3 箱型图中位数高、上下四分位距较窄且离散性较小表明该方法在多任务多分类问题中具有优异的稳定性与泛化能力。

综上,CB Loss 能够增强对少数类样本的关注,ASL 有效缓解了类别不平衡问题且不增加易分类负样本数量。两者结合形成的 CB-ASL-TimesNet 展现出显著的综合优势,适用于处理严重类别不平衡的复杂驾驶场景预测任务。与 TimesNet 相比,后者在部分任务和类别上的指标呈现明显两极分化,上下须接近 0 和 1,这主要是由于少数类别样本量较少使指标对错误预测高度敏感,而多数类别预测几乎完全正确。CB-ASL-TimesNet 在多任务多类别上的表现更加均衡,上下须跨度显著缩小,有效缓解了指标两极分化现象。

4 结 论

1) 融合多周期分析和卷积结构的 TimesNet 多任务预测模型在 4 项任务平均准确率上达到 0.876 4,相比 CNN、GRU、Transformer 和 TimeMixer

模型分别提升 6.13%、2.04%、2.91% 和 1.78%,在时序建模能力和整体稳定性上表现最优。该方法能够增强模型对复杂驾驶行为时序信号的特征表达能力,从而提升行驶风险和转向意图预测的性能。

2) CB Loss 和 ASL 可有效缓解类别不平衡问题,试验结果显示,CB-ASL-TimesNet 模型较原始 TimesNet 模型提高 3.76%,显著提升了少数类的预测性能,提高了整体预测的稳健性和准确率。

3) 结合 CB Loss 函数、ASL 函数与 TimesNet 的 CB-ASL-TimesNet 模型,在多任务多类别预测中表现优异,试验结果显示,该模型在准确率、 F_1 值及召回率等多项指标上均优于传统基线模型,验证了该模型在行驶风险和转向意图预测中的有效性。未来工作可从超参数优化、多源自然驾驶数据适应性验证及多模态感知融合建模 3 方面展开,以便提升模型性能与实际应用价值。

参 考 文 献

- [1] World Health Organization. Global status report on road safety 2023[EB/OL]. [2025-04-02]. <https://www.who.int/teams/social-determinants-of-health/safety-and-mobility/global-status-report-on-road-safety-2023>.
- [2] 严新平,褚端峰,刘佳仑,等. 智能交通发展的现状、挑战与展望[J]. 交通运输研究,2021,7(6):2-10.
Yan Xinping, Chu Duanfeng, Liu Jialun, et al. Status quo, challenges and perspectives of intelligent transportation development[J]. Transport Research, 2021,7(6):2-10.
- [3] Yan Lixin, Huang Zhen, Zhang Yishi, et al. Driving risk status prediction using Bayesian networks and logistic regression[J]. Iet Intelligent Transport Systems, 2017, 11(7):431-439.
- [4] Xiong Xiaoxia, Chen Long, Liang Jun. Vehicle driving risk prediction based on Markov chain model[J]. Discrete Dynamics in Nature and Society, 2018, 2018(1): DOI:10.1155/2018/4954621.
- [5] 温惠英,黄坤火,赵胜. 基于机器学习的高速公路大型货车追尾风险预测[J]. 中国安全科学学报,2023,33(9):173-180.
Wen Huiying, Huang Kunhuo, Zhao Sheng. Prediction of rear-end collisions risk of freeway trucks based on machine learning[J]. China Safety Science Journal, 2023, 33(9):173-180.
- [6] 郭小刚,李彤. 基于随机森林与逻辑回归模型的交通事故严重程度的预测研究[J]. 计算机科学与应用,2019,9(10):1920-1927.
Guo Xiaogang, Li Tong. Prediction of traffic accident severity based on random forest and logistic regression model[J]. Computer Science and Application, 2019, 9(10):1920-1927.
- [7] 朱彤,秦丹,魏雯,等. 基于机器学习的公交驾驶员事故风险识别及影响因素研究[J]. 中国安全科学学报,2023,33(2):23-30.
Zhu Tong, Qin Dan, Wei Wen, et al. Research on accident risk identification and influencing factors of bus drivers based on machine learning[J]. China Safety Science Journal, 2023, 33(2):23-30.
- [8] 陈佳钦,袁健. 基于机器学习与双向时间序列数据的车辆行驶行为预测模型[J]. 建模与仿真,2023,12(3):2994-3007.
Chen Jiaqin, Yuan Jian. Vehicle driving behavior prediction model based on machine learning and Bi-Directional time series data[J]. Modeling and Simulation, 2023, 12(3):2994-3007.
- [9] 赵海涛,程慧玲,丁仪,等. 基于深度学习的车联边缘网络交通事故风险预测算法研究[J]. 电子与信息学报,

2020, 42(1): 50–57.

Zhao Haitao, Cheng Huiling, Ding Yi, et al. Research on traffic accident risk prediction algorithm of edge internet of vehicles based on deep learning[J]. Journal of Electronics & Information Technology, 2020, 42(1): 50–57.

- [10] 高镇海, 鲍明喜, 高菲, 等. 基于 LSTM 概率多模态预期轨迹预测方法[J]. 汽车工程, 2023, 45(7): 1145–1152.
- Gao Zhenhai, Bao Mingxi, Gao Fei, et al. The method of probabilistic multi-modal expected trajectory prediction based on LSTM[J]. Automotive Engineering, 2023, 45(7): 1145–1152.
- [11] Jin Zhixiong, Noh B. From prediction to prevention: leveraging deep learning in traffic accident prediction systems[J]. Electronics, 2023, 12(20): DOI: 10.3390/electronics12204335.
- [12] Lee W H, Chang Chenyu. Assessing driving risk level: harnessing deep learning hybrid model with intercity bus naturalistic driving data[J]. IEEE Access, 2025, 13:25141–25153.
- [13] Yu Rongjie, Wang Yiyun, Zou Zihang, et al. Convolutional neural networks with refined loss functions for the real-time crash risk analysis[J]. Transportation Research Part C: Emerging Technologies, 2020, 119: DOI: 10.1016/j.trc.2020.102740.
- [14] 王博文, 王景升, 吴恩重. 面向不平衡数据集的 SMOTENC-XGBoost 驾驶人交通安全评估模型[J]. 科学技术与工程, 2023, 23(2): 831–837.
- Wang Bowen, Wang Jingsheng, Wu Enzhong. SMOTENC-XGBoost driver traffic safety assessment model for unbalanced dataset[J]. Science Technology and Engineering, 2023, 23(2): 831–837.
- [15] Wang Ke, Xue Qingwen, Lu J J. Risky driver recognition with class imbalance data and automated machine learning framework[J]. International journal of environmental research and public health, 2021, 18(14): DOI: 10.3390/ijerph18147534.
- [16] Wen Wei, Wang Jiankun. Intention-based and risk-aware trajectory prediction for autonomous driving in complex traffic scenarios[C]. 2025 IEEE International Conference on Real-time Computing and Robotics (RCAR). IEEE, 2025, 9: 345–350.
- [17] Romera E, Bergasa L M, Arroyo R. Need data for driver behaviour analysis? presenting the public UAH-DriveSet[C]. 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2016: 387–392.
- [18] Cheng Yushu, Zhao Bochao. Risk assessment method of solar smart grid network security based on TimesNet model[J]. Applied Sciences, 2025, 15(6): DOI: 10.3390/app15062882.
- [19] Wu Haixu, Hu Tengge, Liu Yong, et al. TimesNet: temporal 2D-variation modeling for general time series analysis[J]. arXiv, 2023: DOI: 10.48550/arXiv.2210.02186.
- [20] 杨莲, 石宝峰, 董轶哲. 基于 Class Balanced Loss 修正交叉熵的非均衡样本信用风险评价模型[J]. 系统管理学报, 2022, 31(2): 255–269.
- Yang Lian, Shi Baofeng, Dong Yizhe. A credit risk evaluation model for imbalanced data classification based on class balanced loss modified cross entropy function[J]. Journal of Systems & Management, 2022, 31(2): 255–269.
- [21] 胡红梅, 张丽红. 基于残差注意和非对称损失的行人属性识别[J]. 测试技术学报, 2023, 37(2): 99–105.
- Hu Hongmei, Zhang Lihong. Recognition of pedestrian attributes based on residual attention and asymmetric loss[J]. Journal of Test and Measurement Technology, 2023, 37(2): 99–105.



作者简介: 程方明 (1982—), 男, 辽宁本溪人, 博士, 教授, 主要从事城市公共安全、应急管理及气体粉尘爆炸防控等方面的研究。E-mail: chengfm@xust.edu.cn。