

DOI: 10.13382/j.jemi.B2508668

融合信息熵不确定性与驾驶风格的行驶风险评测方法研究^{*}

曾超杨 刘 平 罗浩轩 刘明杰 朴昌浩
(重庆邮电大学自动化学院 重庆 400065)

摘 要:针对传统风险评测方法多依赖确定性指标,难以对周车行为不确定性进行动态量化风险评测的不足,提出一种融合信息熵不确定性与驾驶风格的风险评测方法,通过信息熵量化车辆运动状态的不确定性,并将不同驾驶风格量化为不同风险值以评测车辆行驶风险。首先,提出了基于信息熵的车辆运动状态不确定性评估方法用于感知行车风险;然后,在车辆速度、加加速度以及车头时距特征下基于 K-means 聚类开展了多种车辆驾驶风格识别;同时,结合权重机制构建了驾驶风格与信息熵融合的行驶风险评测方法;最后,在拥堵道路与高速场景下进行测试,从真实车辆能耗数据入手分析风险评测与车辆能耗的相关性,并与人工势场法、确定性风险评测法和基于学习的风险评测法进行对比。测试结果表明,提出方法均能对不同事件进行风险检测,响应时间指标上较其他 3 种方法分别平均降低 50.55%、86.35%和 81.85%,计算时间显著低于人工势场法和基于学习的方法,显示出该方法在行驶风险评测上的有效性和应用价值。

关键词: 行驶风险;不确定性;信息熵;驾驶风格;风险评测

中图分类号: TP273;TH166 **文献标识码:** A **国家标准学科分类代码:** 510.80

Research on a driving risk assessment method integrating information entropy uncertainty and driving style

Zeng Chaoyang Liu Ping Luo Haoxuan Liu Mingjie Piao Changhao
(College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Traditional risk assessment methods mostly rely on deterministic indicators, making it hard to dynamically quantify risks from the uncertainty of surrounding vehicle behaviors. To address this limitation, this study proposes a risk assessment approach integrating information entropy-based uncertainty quantification and driving style. Specifically, information entropy quantifies the uncertainty of vehicle motion states, while different driving styles are converted into quantifiable risk values for driving risk evaluation. Firstly, an information entropy-based method assesses the uncertainty of vehicle motion states for real-time risk perception. Secondly, K-means clustering is applied to vehicle speed, jerk, and time headway to identify diverse driving styles. A weighted mechanism is then established to fuse driving style and information entropy for the proposed risk assessment model. Finally, experiments are conducted under congested and highway scenarios. The correlation between evaluated risks and actual vehicle energy consumption is analyzed, and comparisons are made with the artificial potential field method, deterministic risk assessment method, and learning-based risk assessment method. Results show that the proposed method reliably detects risks in various events. In terms of response time, it is reduced by an average of 50.55%, 86.35%, and 81.85% compared with the other three methods, respectively. Meanwhile, its computation time is significantly lower than that of the artificial potential field method and the learning-based risk method, demonstrating the effectiveness and application value of the proposed method in driving risk assessment.

Keywords: driving risk; uncertainty; information entropy; driving style; risk assessment

0 引言

复杂场景下的潜在危险对车辆行驶安全构成了严峻挑战^[1],特别是在日益增长的汽车保有量和复杂道路场景下,车辆行驶风险不仅危及驾驶员生命和财产安全,也给不同道路场景下的自动驾驶技术带来了挑战。2024年我国交通事故死亡人数为61 703人^[2],大部分的事故与行驶风险相关^[3]。因此,有效评测周围车辆对自车的行驶风险是避免发生潜在交互危险的基础^[4],对于车辆安全行驶至关重要^[5]。

目前,评估车辆行驶风险主要有人工势场法^[5-6]、指标法^[7-8]以及基于学习的方法^[9]等,如碰撞时间、反应时间或转向时间来量化碰撞风险并给定权重分配方案。同时,风险评估同样是衡量区域环境危险程度或路径风险程度的方法^[10]。在车辆行驶风险评估中,Liang等^[5]提出了一种基于车道概率碰撞风险评估的人机合作驾驶共享控制分配策略,该方法首先根据车道划分机动行为,并计算目标车道概率,随后通过人工势场值与车道概率结合得到碰撞风险。然而,该方法的车道概率是根据车辆的意图来判断所属车道的可能性,但在车辆纵向运动状态的随机波动以及车辆交互等不确定因素方面并未考虑,而且人工势场以轨迹点间距离或相对位置构造势场并进行叠加,其风险强度对势场参数与权重设定较为敏感,对风险突变在理论上缺乏解释。Li等^[7]提出了一种基于驾驶意图识别和情境评估的共享控制驾驶员辅助系统,该方法利用多类学习不确定性分类器识别驾驶意图(如车道保持、左/右换道),并基于碰撞时间和车头时距等指标评估风险水平,以动态分配人机控制权重。然而,该方法依赖于确定性指标,如碰撞时间、车头时距,其计算虽然简单且快速,但面对复杂场景的车辆突发行为的响应存在不足,场景泛化能力较弱。Wang等^[8]提出了一种无需专家规则的数据驱动风险评估方法,该方法利用强化学习和对抗代理来量化风险,通过门控网络进行多变量时间序列回归,分析历史数据以生成对抗代理策略,并在模拟环境中验证其鲁棒性和精确性,避免了传统规则依赖,强调了对抗性行为对自车性能的干扰度作为风险度量。但是,该方法依赖强化学习的训练过程可能导致计算复杂性和高资源消耗,不利于实时应用。上述确定性方法从车辆本身的运动参数(横摆角速度、加速度等)简化风险模型,仅适用于车流量稀疏的高速路段的风险预测^[11]。针对智能汽车拟人行驶风险量化方法难以适应驾驶场景的复杂性,李海青等^[12]提出了基于人类风险感知机理的智能汽车拟人行驶风险的量化方法,但该方法建立的动态风险场仅在各种单一障碍物车辆场景下进行验证,缺乏复杂场景的应对能力。Ma等^[9]提出用真

实高速路的细粒度危险驾驶行为运动学数据,构建事故风险预测模型,用深度森林提升预测与泛化,用沙普利加法解释(SHAP)做可解释性,最终得到一个能解释的动态事故风险预测框架。Zheng等^[13]在功能安全领域从ISO26262的风险评估流程出发对车载系统的功能失效风险进行结构化分析与量化评估,通过云模型细化汽车安全完整性等级边界、用故障树分析构建自动紧急制动系统等车载系统的潜在失效路径,并对基本事件进行风险排序与敏感性分析,从而量化顶事件(系统失效)的概率,但评估对象以系统功能失效为主,缺乏对真实交通场景中车—车交互、驾驶操作、运动状态不确定性等动态因素的直接建模。张会明等^[14]也指出驾驶人认知控制能力在面对突发交通事件时比面对预期事件风险能力偏弱,说明驾驶员个体之间的行车差异与风险也息息相关,其对于风险评测也不容忽视。

可以看出,传统的人工势场法由于以相对距离接近关系构造势场并叠加求风险,容易实现但对势场建模以及参数权重敏感,且对于拥堵道路场景下车辆之间的高强度交互引发的风险缺少解释;确定性方法具有计算效率高的优点,但方法本身是通过专家经验来设定指标在各个风险等级之间的阈值点,在阈值点之间的范围并没有描述风险的变化,也就无法衡量车辆之间交互的不确定性;基于学习的方法可拟合复杂的非线性关系,但受数据覆盖以及训练开销限制,而且其风险结论不可解释,计算时间长影响实时部署。因此,针对上诉传统风险评测方法难以对周车行为的不确定性进行动态量化风险评估的不足,本文提出一种融合信息熵不确定性与驾驶风格的行驶风险评测方法来描述车辆突发行为的不确定性运动状态,并引入驾驶风格刻画主观个性带来的风险以提高评测的全面、可解释性与多场景适应能力。

考虑到信息熵^[15]作为信息论中的一个基本概念,对于衡量信息的不确定性或随机性具有很好表现,为量化周围车辆的不确定性行为提供了理论基础,本文基于此构建广义的车道信息熵度量。同时,在风险预测中,人类或自动驾驶系统行为偏离预期输入时产生意外风险因素也不容忽视^[16]。因而,本文将驾驶风格也纳入车辆行驶风险评测的基本要素中,综合驾驶行为与信息熵开展行驶风险评估。为了验证本文方法的有效性,引入能效数据集,以车辆轨迹、燃油消耗、能源使用、速度和辅助动力装置使用情况等时间序列数据^[17],进行风险评测与能耗相关性分析。进一步,通过构建不同的交通场景,对提出方法进行测试验证。本文针对车辆状态不确定性在风险评测中难以动态量化问题,引入信息熵理论,通过分析车辆状态的概率分布来度量不确定性程度,解决传统方法难以有效处理不确定性行为的问题,实现对车辆行驶风险动态感知;引入分析驾驶风格特性,提出一种融合信息

熵与驾驶风格的风险评测方法,能够在动态量化车辆状态的客观改变的同时综合考虑驾驶员主观个性因素影响;引入能耗数据集作为验证工具,分析风险评分与车辆实际能耗高低的相关性,解决风险评测方法可行性验证依赖主观或模拟数据的局限性,并从实车数据上测试验证提出方法的有效性和实际应用价值。

1 整体方案设计

本文根据信息熵可以衡量系统不确定性的特点,将其泛化至车辆行驶风险评测中以此来量化车辆行驶过程中运动状态改变的不确定性。同时,驾驶风格作为衡量驾驶员主观操作风险的重要因素之一,本文将引入与

熵风险共同评测车辆行驶风险。在上述思路下,本文的整体方案设计如图1所示。考虑到不同场景下的车辆行驶与车间特征不同(速度、加速度、车头时距等),不同算法部署难易程度存在差异,对周围车辆实时数据获取并聚类以及熵值的同步求解会带来较大计算开销。因此,在图1中本文设置了离线数据库,对不同场景下的真实行车数据集进行处理,获取该特征场景下的车辆行驶特点并筛选车辆与车辆之间的常见指标;进一步,通过核密度估计法以及车间特征聚类得到场景下的车辆状态概率以及驾驶风格便于后续快速计算车辆熵值以及对应的驾驶风格,从而计算熵和驾驶风格分别带来的行驶风险;最后,本文通过权重机制进行融合,得到融合后车辆行驶风险。




图1 评测方法整体方案设计

Fig. 1 Overall scheme design for the evaluation method

2 基于信息熵的风险量化

熵在热力学中的物理意义表示体系混乱程度的度量,随后其启发了其他学科对庞杂系统状态、特征的量化表达,如信息熵,它是对研究事件不确定性程度的度量,信息量越大,无序度越大,熵越大;信息量越小,无序度越小,熵越小^[18]。而在行驶道路中,由于车与车之间的速度、加速度通常较低,而车头时距较高。因此,本文认为车辆在该场景下,信息量越小,不确定性越大,熵越大,而信息量越大,不确定性越小,熵越小。香农^[19]对熵的定义式为:

$$H(X) = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (1)$$

式中: $p(x_i)$ 表示随机事件 X 为 x_i 的概率。本文考虑车辆道路行驶中的信息熵泛化,根据其他车辆的状态对车辆的影响来量化风险程度。

2.1 车辆信息熵性质

将车辆行驶时的车道空间视作一个封闭的系统,以周围其他车辆为信息源,可以得到以下车辆信息熵的性质。

推理1 车辆行驶状态分布均匀情况下,目标车辆周围车辆的信息熵存在极值。

证明:对于行驶车辆,可以用3种状态(相对加速、减速以及静止)评估车辆的行驶状态。当车辆状态分布均匀时,即概率分别为 $p_\alpha = p_\beta = p_\delta = 1/3$,可以得到车辆状态信息熵公式为:

$$H_{dyn} = -p_\alpha \log_a p_\alpha - p_\beta \log_a p_\beta - p_\delta \log_a p_\delta \quad (2)$$

式中: $a > 0$ 且 $a \neq 1$ 。利用拉格朗日乘子法,对约束 $p_\alpha + p_\beta + p_\delta = 1$ 进行分析,构造拉格朗日函数得到:

$$L = -p_\alpha \log_a p_\alpha - p_\beta \log_a p_\beta - p_\delta \log_a p_\delta + u(p_\alpha + p_\beta + p_\delta - 1) \quad (3)$$

式中: u 为拉格朗日算子。根据极值理论可知,拉格朗日函数式(3)满足如下条件时存在极值:

$$\begin{cases} \frac{\delta L}{\delta p_\alpha} = -(\log_a p_\alpha + \frac{1}{\ln a}) + u = 0 \\ \frac{\delta L}{\delta p_\beta} = -(\log_a p_\beta + \frac{1}{\ln a}) + u = 0 \\ \frac{\delta L}{\delta p_\delta} = -(\log_a p_\delta + \frac{1}{\ln a}) + u = 0 \end{cases} \quad (4)$$

化简整理式(4)后可得:

$$\log_a p_\alpha = \log_a p_\beta = \log_a p_\delta \quad (5)$$

将式(5)和 $p_\alpha = p_\beta = p_\delta = 1/3$ 代入式(2)可得极值为:

$$H_{dyn} = \log_a 3 \quad (6)$$

推理 1 由此得证。

推理 2 当某车辆一状态概率趋于 1 时,熵趋于 0。

证明:假设 $p_\alpha \rightarrow 1, p_\beta \rightarrow 0, p_\delta \rightarrow 0$, 则根据式(2)有:

$$\lim_{p_\alpha \rightarrow 1} \log_a p_\alpha = 0 \quad (7)$$

且 p_β, p_δ 也趋于 0, 由此可得:

$$\lim_{p_\alpha \rightarrow 1} H_{dyn} = 0 \quad (8)$$

推理 2 由此得证。

推理 2 表明当车辆状态确定时(熵趋于 0), 车辆风险最小。当车辆状态越不可预测时(熵远离 0)风险越高。

2.2 车辆信息熵风险计算方法

根据上述车辆信息熵推理, 进一步引入对象状态或者事件的概率分布。考虑到车辆速度和加速度直接反映驾驶效率 and 安全性, 本文优先选取这两个参数来表征车辆状态, 并基于数据集实现信息熵风险的计算^[20]。首先, 使用如下核密度估计(kernel density estimation, KDE)来估计车辆的概率密度函数^[21]。

$$\hat{f}(x, y) = \frac{1}{nh_x h_y} \sum_{i=1}^n K\left(\frac{x - x_i}{h_x}, \frac{y - y_i}{h_y}\right) \quad (9)$$

式中: x 和 y 分别代表车辆的速度和加速度; $\hat{f}(x, y)$ 代表给定状态点处的估计概率密度值; n 表示样本点总数; h_x 和 h_y 是带宽参数; $K(\cdot)$ 代表核函数。本文选择高斯核作为核函数^[22], 带宽设置为:

$$h = 1.06\sigma n^{-0.2} \quad (10)$$

式中: σ 表示标准差。结合上述理论, 以历史交通数据为示例计算了车辆在不同速度与加速度组合中的联合概率密度函数, 其结果如图 2 所示。

图 2 中, 越接近黄色中心区域, 表示具有该特定速度和加速度组合的车辆密度越高。进一步, 对车辆在不同状态下的信息熵采取标准化处理, 最终构建了车辆熵风险值 H_i :

$$H_i = - \frac{\sum_{i=1}^n p(v_i, a_i) \log_a(p(v_i, a_i))}{H_{\max} - H_{\min}} \quad (11)$$

式中: $v_i, a_i, H_{\max}$ 和 $H_{\min}$ 分别代表第 i 辆车的速度、加速度




图 2 核密度估计等高线图

Fig. 2 KDE contour plot

状态, 先验数据集中最大熵和最小熵值。

结合上述定义, 利用信息熵量化车辆周围车辆行驶风险, 提出车辆信息熵风险计算方法, 其实现伪代码如下。

算法 1 车辆信息熵风险算法

输入: 车辆状态序列(速度 V & 加速度 A), 先验 KDE 数据, 设定参数

- 1: 车辆状态 $state \leftarrow \text{GetRealtimeData}()$
- 2: 车辆基础熵值 $H_{\text{raw}} \leftarrow \text{CalculateBasedEntropy}(state)$
- 3: 核密度估计值边界 $p_{\min}, p_{\max} \leftarrow \min(P_{\text{valid}}), \max(P_{\text{valid}})$ 有效最大/最小核密度值
- 4: For $p; \text{length}(P_{\text{valid}})$
- 5: 有效熵值集合 $H_{\text{all}} \leftarrow -\log(p)$
- 6: End for
- 7: 熵值范围 $H_{\text{range}} \leftarrow \max(H_{\text{all}}) - \min(H_{\text{all}})$
- 8: IF $\text{normalize_flag} = \text{true}$ 熵值范围标准化
- 9: for $i; n$
- 10: $h_{\text{norm_i}} \leftarrow (H_{\text{raw}}[i] - h_{\min}) / h_{\text{range}}$
- 11: $h_{\text{norm_i}} \leftarrow \max(0, \min(1, h_{\text{norm_i}}))$ 限制标准化范围
- 12: end for
- 13: End if
- 14: if $h_{\text{norm}} < 0.3$
- 15: $\text{risk_level} \leftarrow$ "低风险, 车辆状态比较可预测"
- 16: else if $h_{\text{norm}} > 0.4 \ \&\& \ h_{\text{norm}} < 0.75$
- 17: $\text{risk_level} \leftarrow$ "中等风险, 车辆状态可预测性一般"
- 18: else if $h_{\text{norm}} > 0.75 \ \&\& \ h_{\text{norm}} < 1$
- 19: $\text{risk_level} \leftarrow$ "高风险, 车辆状态非常不可预测"
- 20: End if

输出: 风险值 h_{norm} , 风险等级 risk_level

3 驾驶风格的风险计算

描述驾驶行为的信息对降低行车风险至关重要, 这促使学术界研究者开发多种技术来评估分析驾驶行为与

风格。当前,最常见驾驶行为从交通安全角度可划分为3大类,分别为保守型驾驶、正常型驾驶、激进型驾驶^[23-25]。为了将不同道路场景下车辆的驾驶风格和其对应的风险联系起来,本文引入道路数据集,通过提取数据集中车辆的速度、加加速度以及车头时距等获取驾驶风格特征,在清洗数据集基础上,采用K均值聚类(k-means clustering, K-means)将其分为3类,分别为激进型驾驶、正常型驾驶、保守型驾驶。结合上述思路,本文给出拥堵道路场景数据下的结果示意如图3所示。




图3 驾驶风格聚类

Fig. 3 Driving style clustering

在此基础上,本文将3个类型的驾驶风格划分为3类风险值范围。激进型驾驶风格(z_1, z_2);正常型驾驶风格(z_3, z_1);保守型驾驶风格(z_4, z_3)。在真实行车环境中,监测车辆的状态并将其量化为具有驾驶风格的风险值需要统一数值范围差异较大的速度、加加速度、车头时距的量纲,则单个类别 j 的标准化为:

$$z_{ij} = \frac{x_{ij} - u_j}{\sigma_j} \quad i = 1, 2, \dots, n; \quad j = 1, 2, 3 \quad (12)$$

式中: x_{ij} 代表第 j 个类别中的第 i 个数据点; u_j, σ_j 分别为第 j 个类别的均值和标准差,通过式(13)和(14)计算。

$$u_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (13)$$

$$\sigma_j = \sqrt{\left(\sum_{i=1}^n (x_{ij} - u_j)^2 \right) / (n - 1)} \quad (14)$$

进一步,在得到标准化值后,根据实时监测到的车辆状态数据并利用欧几里得公式,如式(15)所示,来确保每个类别对距离计算的贡献是平等的。

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (15)$$

进而根据式(12)和(15),在车辆任意时刻状态下,得出欧氏距离,然后对其进行Z分数标准化(z-score standardization, Z-Score)得到风险值如下:

$$d_m = \sqrt{\sum_{n=1}^3 (q_n - c_{mn})^2} \quad (16)$$

式中: n 代表3个特征(速度、加加速度、车头时距); d_m 代表新样本到第 m 个聚类中心的距离; q_n 表示新样本的第 n 个标准化特征值; c_{mn} 表示第 m 个聚类中心的第 n 个

特征值。当车辆行驶时,通过式(12)和(15)计算出该状态下的车辆与3种驾驶风格聚类中心的距离实现车辆驾驶风格的归类并赋予风险值。本文提出的基于驾驶风格的风险计算方法伪代码如下。

算法2 驾驶风格风险计算

输入:车辆状态序列(车头时距 THW& 速度 V& 加速度 A),聚类数量 $k=3$,设定参数

```

1: 加载预训练的聚类模型  $M \leftarrow \text{Load}('drivingStyleClusterModel.mat')$ 
2: 提取模型参数:
3: 聚类中心  $C \leftarrow M.\text{centroids } k \times 3$  矩阵
   风险范围  $R \leftarrow M.\text{riskScoreRanges}$  各聚类的风险评分范围
4: 状态向量  $X \leftarrow [THW, V, A]$ 
5: 标准化输入  $X_{\text{norm}} \leftarrow (X - \mu) / \sigma$  Z-score 标准化
6: for  $i = 1: k$ 
7: 距离  $d[i] \leftarrow ||X_{\text{norm}} - C[i]||^2$  计算欧氏距离
8: end for
9: clusterLabel  $\leftarrow \text{argmin}(d)$  // 找到最近的聚类索引
10:  $[r_{\text{min}}, r_{\text{max}}] \leftarrow R[\text{clusterLabel}]$  // 获取该聚类的风险范围
    riskScore  $\leftarrow r_{\text{min}} + (r_{\text{max}} - r_{\text{min}}) \times d / (d+1)$ 
11: end for
12: End if
13: if riskScore  $\geq 0.75$ 
14: RiskDescribe  $\leftarrow$  "高风险,激进驾驶不稳定"
15: else if riskScore  $> 0.4$  && riskScore  $< 0.75$ 
16: RiskDescribe  $\leftarrow$  "中等风险,正常型驾驶风格"
17: else if riskScore  $> 0$  && riskScore  $< 0.4$ 
18: RiskDescribe  $\leftarrow$  "低风险,驾驶行为保守"
19: End if
输出:风险值 riskScore,风险描述 RiskDescribe

```

4 融合信息熵与驾驶风格的风险评测

基于信息熵理论,以数据集为基础,利用核密度估计方法构建了信息熵风险的数据驱动库;同时,对道路场景中历史行车数据进行K-means聚类得到激进型、正常型、保守型3种类型驾驶风格并作为驾驶风格的驱动数据。当车辆行驶时,传感器检测到周围车辆时,将其车辆状态作为本文风险计算的输入,进一步调用数据驱动库获取原始信息熵值,将其结果标准化,配合风险值的划分,可以得到该车辆的风险等级并同时输出信息熵风险值。融合信息熵与驾驶风格的风险评测流程如图4所示。可以看出,驾驶风格的计算与信息熵风险值计算同步进行,在接收到车辆的状态信息后,加载预训练聚类模型,根据该车辆目前状态与聚类中心的欧式距离确定该车辆的类别,进而在类型确定的基础上得到驾驶风格的风险等级和风险值。此外,本文在构建融合风险值函数时,引入了信息熵风险权重系数 A 与驾驶风格风险权重 B 来反映车辆运行时的重要性。车辆的驾驶风格反映车辆之间的博弈关系,而信息熵衡量车辆本身运动状态的

不确定性带来的风险,两者同等重要,因此融合风险值函数如式(17)所示。

$$R_{u,i} = AH_i + BS_i \quad (17)$$

式中: $R_{u,i}$ 为融合风险值; S_i 为驾驶风格风险值。




图 4 融合信息熵与驾驶风格的风险评测流程

Fig. 4 A risk review flowchart integrating information entropy and driving style

本文方法的时间复杂度为线性复杂度,每个时间步主要包括信息熵风险计算、驾驶风格风险计算与风险融合 3 部分。信息熵风险部分:离线阶段已完成概率分布构建与数据驱动库建立,在线阶段对每辆车仅进行一次插值与常数次算术运算,因此单车为 $O(1)$, 离线阶段计算复杂度为:

$$T_{ent}(N) = N \cdot O(1) = O(N) \quad (18)$$

驾驶风格风险部分,聚类中心数量为常数(3 类风格),对每辆车只需计算与有限个中心的距离并取最小值,单车为 $O(1)$, 驾驶风格计算阶段为:

$$T_{style}(N) = N \cdot O(1) = O(N) \quad (19)$$

融合风险部分,对每辆车执行常数次加权求和与阈值判断,单车为 $O(1)$, 融合风险计算为:

$$T_{fuse}(N) = O(N) \quad (20)$$

因此,本文方法在线阶段每帧总时间复杂度为:

$$T_{ou}(N) = T_{ent}(N) + T_{style}(N) + T_{fuse}(N) = O(N) \quad (21)$$

式中: N 为单帧评估时刻需要考虑周围车辆数量; d 为单车状态维度; $O(N)$ 为线性时间复杂度。

5 实验测试

5.1 实验方案设计

风险评测方法的有效性通过能耗相关性测试与场景测试进行,其中能耗相关性测试旨在验证方法的结果是

否与相同运动状态下现实场景车辆的能耗具有一致性,从而证明方法符合车辆动力学以及能量消耗的物理规律^[26]。同时,本文还在不同场景下对比本文方法与人工势场法、确定性法、基于学习法在计算时间、响应时间、场景泛化能力 3 个指标下的表现,整体实验方案设计如图 5 所示。

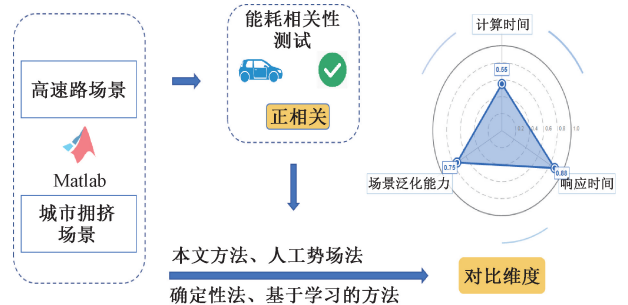


图 5 实验方案设计

Fig. 5 Experimental scheme design drawing

本文测试在 MATLAB R2021a 平台进行,测试验证使用的计算机配置如下:处理器为 AMD Ryzen 7 6800H 3.2GH, 6GB-RAM 存储, NVIDIA GeForce RTX 3050 Laptop GPU。测试所采用的参数设置如表 1 所示。表 1 中, K_r 为人工势场斥力系数, $DRAC_m$ 、 $DRAC_c$ 分别为避免碰撞最大减速度和舒适减速度, A 、 B 分别为信息熵风险权重值与驾驶风格风险权重值, z_1 、 z_2 、 z_3 、 z_4 分别为驾驶类别阈值参数。

表 1 实验主要参数设置

Table 1 Main parameters for the experiments			
参数	值	参数	值
K_r	20	$DRAC_e$	3.4
$DRAC_m$	6.2	A	0.5
z_1	0.75	B	0.5
z_2	1	z_4	0
z_3	0.4		

5.2 能耗相关性测试

为了验证本文提出融合风险评测结果是否与真实车辆在相同运动状态下的能耗变化趋势保持一致,本文基于实车能耗数据进行了相关性测试。利用本文构建的信息熵风险与驾驶风格风险,对车辆在不同工况下的行驶状态进行风险量化;选取真实能耗数据集中对应时刻的能耗(功率)作为物理参照量,通过相关性分析观察两者之间的映射关系,若高风险评分与高能耗水平在统计意义上呈显著正相关,则可以认为风险评测结果在物理上是合理的,为方法的客观有效性提供支撑。能耗相关性测试基于密歇根大学公开的车辆能源数据集(vehicle energy dataset, VED)能耗数据集开展。

在测试中,首先从 VED 数据集中选取具有代表性的城市道路片段,去除异常或缺失的数据点,构建清洗后的时间序列样本集。随后,利用 VED 中的车辆速度和加速度等运动学变量以及车头时距作为输入。在此基础上,根据式(17)进一步得到融合风险序列。最后,从 VED 数据中提取与上述风险序列在时间上对齐的能耗指标,以单位时间能耗作为能耗评价量开展相关性分析。具体地,从 VED 数据集筛选 90 s 场景车辆行驶数据构成相关性测试的基础,并在此场景下模拟车辆的 6 个不同动态过程(启动与加速、稳定巡航、交通拥堵、缓慢跟车、激进超车、恢复正常驾驶)来探索风险与能耗之间的关系。此外,本文采用皮尔逊相关系数来度量这两个变量之间的线性相关强度。

熵值风险、驾驶风格风险以及融合风险与能耗之间的相关性散点分布如图 6~8 所示。可以看出,3 种风险指标与能耗之间均表现出明显的正相关趋势,在车辆频繁加速、减速或保持较小车头时距等激进行驶状态下,风险评分显著升高,同时瞬时能耗或功率水平也明显增加。其中,熵值风险与能耗的皮尔逊相关系数为 0.765 7,驾驶风格风险与能耗的皮尔逊相关系数为 0.768 0,而融合风险与能耗的皮尔逊相关系数则为 0.802 3。相较单一的信息熵风险或驾驶风格风险,融合风险与能耗之间的线性相关性更强,表明将车辆运动不确定性与驾驶风格特征纳入风险评测框架,可以更准确刻画高能耗工况所对应的高风险驾驶状态,显示出融合后方法的有效性。




图 6 熵值风险与能耗相关性

Fig. 6 Correlation between entropy risk and energy consumption




图 7 驾驶风格与能耗相关性

Fig. 7 Relationship between driving styles and energy efficiency




图 8 融合风险与能耗的相关性

Fig. 8 Integrated effects of entropy and driving styles on risk-energy consumption correlation

此外,相关性测试下的风险值与功率变化趋势如图 9 所示。在车辆起步与加速阶段,融合风险值与功率均快速上升;进入相对稳定行驶阶段后,两者均回落并保持在较低水平;在频繁启停以及激进超车阶段,风险评分与功率曲线再次同步波动上升,最终恢复正常跟车或巡航阶段,又共同回归到较为平稳的波动区间。上述结果表明,本文方法给出的风险评测不仅在统计意义上与能耗高度正相关,而且在时间序列上也与能耗变化过程保持一致。




图 9 融合风险评分值与功率变化曲线
Fig. 9 Integrate the risk score value with the power variation curve

5.3 场景测试

本文在不同场景下测试对比人工势场法、确定性风险评估法以及基于学习法的实时性、计算时间以及场景泛化能力,为此从拥堵和高速两个真实道路场景分别选取片段构建交通流开展动态测试验证。

1) 拥堵道路场景测试

在拥堵道路场景中,车辆需要在有限视野和复杂交通交互下快速、稳定地完成风险评测,对评测方法的实时性和场景适应性提出了较高要求。本文在 MATLAB 中构建的交通流示意图如图 10 所示。该场景中,自车在 60 s 内依次遭遇 3 个典型风险事件,前车突然制动(事件 1)、相邻车道车辆侧向并线(事件 2)以及前方静止事故车辆(事件 3),分别对应图 10 中的 10 号、2 号和 13 号目标车辆。




图 10 拥堵场景下交通流

Fig. 10 Traffic flow in urban congestion scenarios

进一步,采用人工势场法、确定性风险评估法、基于学习的风险评估方法以及本文提出的融合信息熵与驾驶风格的风险评测方法,对自车在整个行驶过程中的风险值进行在线计算,并对比各方法在 3 类风险事件中的响应特性与变化规律,4 种方法得到的风险值随时间变化曲线如图 11 所示。




图 11 城市拥堵道路下 4 种方法风险值变化曲线
Fig. 11 Risk values variation curves of four methods in urban congestion scenario

由图 11 可知,车辆在遭遇前车突然刹车时,本文方法和人工势场法均能在事件出现后感知到风险,并在事件发生后,风险值不断攀升,而确定性风险评估法由于基于车头时距、避免碰撞减速度的指标判断风险,只有当前车速度小于自车速度时才会有风险,前车虽然刹车,但其速度一直略大于自车速度,因此确定性方法在应对该拥堵场景下前车速度变化的泛化能力明显不足。基于学习的方法在此阶段前后保持在 0.22 的风险值左右,没有明显响应。车辆相邻车道出现车辆侧向并线时,自车右边车道存在一辆变道并线行为的车辆,由于该车辆并线行为,10 号车辆降低速度配合其并线使得自车跟随 10 号车辆降速,但由于自车与 10 号车辆间距先缩小后增大,因此本文方法风险曲线呈现出先上升再下降的特点,以此响应前车降速导致的距离迅速减小,而后自车降速后保障安全距离。基于学习的方法在事件 2 前长时间维持在 0.15 左右,在 31 s 快速抬升至约 0.70 并保持一段平台期,随后逐渐回落至 0.15 左右,说明其能够通过训练样本识别到并线冲突,但相较本文方法,对事件早期风险增长的敏感性和对事件结束后风险迅速降低的描述仍然不足。

本文根据 4 种方法对 3 种风险事件发生后检测到风险事件快慢为指标,同时从遭遇 3 个事件的风险响应时间以及计算时间等方面,对几种方法进行性能对比,如表 2 所示。结果表明,车辆遭遇前车突然刹车(事件 1)的情况下,本文方法响应时间与人工势场法一致,均为 0.01 s;遭遇侧车并线以及前方存在事故车辆场景(事件

2、3)下的响应时间分别为0.01和1.3 s,对比人工势场法、确定性法以及基于学习的方法平均时间分别提高了42.7%、92.1%以及93.1%,表明本文评测方法在应对突发的情况下比其他方法能更快响应风险并留出时间给车辆做出合理的决策。此外,4种方法在线计算时间通过

10次测试统计平均单帧运行时间得到,各方法的平均单帧运行时间分别为18.2、3.6、58.7和16.3 ms,本文方法计算时间虽然比确定性方法稍长,但比人工势场法以及基于学习的方法效率分别提升了10.4%和72.2%,显示出所提出方法在计算效率方面的性能。

表2 拥堵道路场景测试性能指标对比
Table 2 Comparison of test performance indicators in congested road scenarios

方法	事件1 响应时间/s			事件2 响应时间/s			事件3 响应时间/s			计算时间/ms		
A	0.01			0.03			1.6			18.2		
B	未能检测风险			1			8.7			3.6		
C	未能检测风险			0.7			10.4			58.7		
本文方法	0.01			0.01			1.3			16.3		
性能提升/%	A	B	C	A	B	C	A	B	C	A	B	C
	一致	—	—	66.7	99.0	98.6	18.8	85.1	87.5	10.4	—	72.2

注:方法A为人工势场法^[27];方法B为确定性法^[28];方法C为基于学习的方法^[9],下同

2) 高速道路场景测试

相比拥堵道路,高速场景下车辆车速更高。为了对比不同风险评测方法在高速工况下的能力,本文构建了三车道真实高速路场景,即自车在60 s内依旧依次遭遇前车突然制动(事件1)、相邻车道车辆侧向并线(事件2)以及前方静止事故车辆(事件3)3类风险事件,分别采用本文方法、人工势场法、确定性风险评估法以及基于学习的方法进行在线风险计算,得到的风险值随时间变化曲线如图12所示。

较好的敏感性,能够在事件附近给出明显高于巡航阶段的风险值。人工势场法在高速场景下风险值整体偏大,由于其方法本身对周围所有车辆的势能进行叠加,而高速场景中同向车辆数量较多,且车速较高导致势场值本身较大,在全程大部分时间内保持在0.8以上,甚至接近0.94。虽然在事件1和2时段有抬升,但整体曲线处于较高位,难以区分不同事件前后的危险程度变化。确定性法依然主要基于碰撞时间、避免碰撞减速度等固定阈值进行判断,当相对距离和相对速度尚未触及阈值时,其始终维持在约0.10~0.15。在高速巡航阶段以及相当一部分事件发生过程中,该方法的风险估计几乎不随场景变化而改变,仅在如在事件1时段(前车突然制动)局部时间段出现尖峰,该时段相对速度和车头间距在短时间内变化较大,碰撞时间短暂触及阈值,出现一次明显峰值;但在事件2时段,尽管并线车辆压缩了自车间距,但仍未跌破指标阈值,因此没有将该工况判定为高风险,曲线仅出现轻微波动,无法对该类高风险并线场景做出有效响应。基于学习的方法在高速场景中受训练数据分布影响,在初期保持在0.65左右,随后在较长时间逐步下降到0.3~0.35;当进入事件1和2时段时,能够较为迅速地抬升,在事件1与2附近风险值均超过了0.8,说明学习方法能够识别训练集中出现过的紧急制动和并线冲突等样本;在事件3时段,整体呈单调下降趋势,最终接近0.16,说明对高速下远端静止障碍物的泛化能力有限。




图12 高速场景下4种方法风险值变化曲线
Fig. 12 Risk value change curves of four methods under expressways

本文方法在高速场景下给出的风险值主要分布在0.52~0.65区间,在巡航阶段,风险值维持在0.53~0.56的中等水平,当进入3个风险事件时,曲线开始抬升,说明高速行驶本身相对于低速工况具有更高的基础风险。此外,信息熵与驾驶风格两个维度对局部工况变化具有

综上可知,本文方法在高速场景下仍能很好的评测风险,并在事件1、2中得出幅度合理、连续变化的风险抬升,既体现了高速工况下车辆状态不确定性的增加,又通过驾驶风格特征对风险水平进行细致调节。进一步,本文统计4种方法在3种风险事件发生后检测到风险的事件快慢、计算时间指标,对比数据如表3所示。由于事件

3 并不是一个立刻能反馈到自车的风险事件,因此 4 种方法对应的响应时间均包含了静止车辆信息出现到感知到前方车辆对应措施的过程时间。由表 3 可知,本文方法在响应时间上比人工势场法、确定性法以及基于学习

的方法平均提高了 58.4%、80.4%和 70.6%。在高速公路场景中,本文方法在计算时间上相较于人工势场法、基于学习的方法分别提升 15.0%、73.0%,进一步验证了所提方法的有效性。

表 3 高速公路场景测试性能指标对比

Table 3 Comparison of performance indicators in high-speed road scenario tests

方法	事件 1 响应时间/s			事件 2 响应时间/s			事件 3 响应时间/s			计算时间/ms		
A	0.04			未能检测风险			0.30			16.7		
B	0.08			未能检测风险			0.70			3.4		
C	0.03			0.24			0.50			52.6		
本文方法	0.02			0.22			0.10			14.2		
性能提升/%	A	B	C	A	B	C	A	B	C	A	B	C
	50.0	75.0	33.3	—	—	98.6	66.7	85.7	80.0	15.0	—	73.0

6 结 论

本文提出了一种融合信息熵不确定性与驾驶风格的行驶风险评测方法。该方法基于真实交通数据构建速度和加速度联合分布的熵风险数据驱动库,以刻画周围车辆运动状态的不确定性;同时通过聚类划分保守型、正常型和激进型驾驶风格,并映射为不同风险等级,最终在统一框架下实现熵风险与驾驶风格风险的加权融合,得到连续可调的行驶风险指标。本文从车辆突发行下的不确定性运动状态量化与驾驶风格建模两个维度上解决了传统的确定性法固定阈值难区分驾驶行为差异、人工势场法参数敏感、场景扩展性低、基于学习的方法训练和算力要求高、难以解释的问题,实现了所研究方法能在不同道路类型和车速条件下对行车风险的动态、实时量化,并兼顾物理一致性。此外,本文开展了能耗相关性实验,对融合风险与实际能耗之间的关系进行了相关性分析,结果表明风险与能耗均存在显著正相关,其中融合风险与能耗的一致性最强,证明了所构建指标在物理层面与高能耗(高风险)驾驶行为的一致性。同时,拥堵和高速两类道路场景下的风险事件测试验证了本文方法的场景泛化能力,显示出所提出方法的有效性。后续,将进一步扩展至交叉口、混合交通、乡村道路等更复杂道路环境,纳入驾驶员状态等更多主观因素,引入权重自适应策略,并尝试将风险评测结果与路径规划和控制决策深度耦合,在闭环控制框架下评估其对碰撞率、舒适性及能耗的综合改善效果。

参考文献

[1] 赵明阳, 梁茨, 徐志刚, 等. 自动驾驶场景安全约束识别的本体增强 STPA 方法[J]. 中国公路学报, 2025, 38(11): 391-402.
ZHAO M Y, LIANG C, XU ZH G, et al. Ontology-enhanced STPA method for safety constraint recognition

in autonomous driving scenarios [J]. China Journal of Highway and Transport, 2025, 38(11): 391-402.
[2] 王丹琦, 刘家豪, 石亮亮, 等. 考虑行人安全的智能车辆制动避撞策略及优化[J]. 西南大学学报(自然科学版), 2025, 47(8): 13-25.
WANG D Q, LIU J H, SHI L L, et al. Intelligent vehicle braking and collision avoidance strategies considering pedestrian safety and their optimization[J]. Journal of Southwest University (Natural Science Edition), 2025, 47(8): 13-25.
[3] LI G, LIAO Y, GUO Q, et al. Traffic crash characteristics in Shenzhen, China from 2014 to 2016[J]. International Journal of Environmental Research and Public Health, 2021, 18(3): 1176.
[4] 周勇, 刘泓滨, 侯亚东. 复杂城市交通场景下的自动驾驶语义分割方法[J]. 电子测量与仪器学报, 2024, 38(4): 241-247.
ZHOU Y, LIU H B, HOU Y D. Semantic segmentation methods for autonomous driving in complex urban traffic scenarios [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 241-247.
[5] LIANG X, ZHAO Y, KANG Y, et al. An authority allocation strategy for shared control in human-machine cooperative driving via lane-based probabilistic collision risk assessment[C]. Proceedings of the 2024 14th Asian Control Conference (ASCC). IEEE, 2024.
[6] YUE M, FANG C, ZHANG H, et al. Adaptive authority allocation-based driver-automation shared control for autonomous vehicles [J]. Accident Analysis & Prevention, 2021, 160: 106301.
[7] LI M, CAO H, SONG X, et al. Shared control driver assistance system based on driving intention and situation assessment [J]. IEEE Transactions on Industrial Informatics, 2018, 14(11): 4982-4994.
[8] WANG C, YANG S, HUANG Y. A data-driven risk

- assessment method for autonomous vehicles without expert rule design [C]. Proceedings of the 2024 IEEE 27th International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2024.
- [9] MA X, HUO Z, LU J, et al. Deep forest with shapley additive explanations on detailed risky driving behavior data for freeway crash risk prediction[J]. Engineering Applications of Artificial Intelligence, 2025, 141: 109787.
- [10] 张宏宏, 甘旭升, 李双峰, 等. 复杂低空环境下考虑区域风险评估的无人机航路规划[J]. 仪器仪表学报, 2021, 42(1): 257-266.
- ZHANG H H, GAN X SH, LI SH F, et al. Route planning for unmanned aerial vehicles considering regional risk assessment in complex low-altitude environments [J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 257-266.
- [11] ZHAO Y, ZHENG X, CHEN X. Intelligent driving risk assessment based on driving risk force field modeling [C]. Proceedings of the 2024 8th CAA International Conference on Vehicular Control and Intelligence (CVCI). IEEE, 2024.
- [12] 李海青, 李永福, 郑太雄, 等. 智能汽车拟人驾驶风险量化方法研究[J]. 电子测量与仪器学报, 2023, 37(8): 120-127.
- LI H Q, LI Y F, ZHENG T X, et al. Research on quantifying risk methods for anthropomorphic driving of intelligent vehicles [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 120-127.
- [13] ZHENG X, LIU Q, LI Y, et al. Safety risk assessment for connected and automated vehicles: Integrating FTA and CM-improved AHP[J]. Reliability Engineering & System Safety, 2025, 257: 110822.
- [14] 张会明, 袁伟, 郭应时, 等. 驾驶人认知控制能力对交通风险事件响应的影响特性[J]. 中国公路学报, 2025, 38(3): 82-96.
- ZHANG H M, YUAN W, GUO Y SH, et al. The influence characteristics of drivers' cognitive control ability on the response to traffic risk events[J]. China Journal of Highway and Transport, 2025, 38(3): 82-96.
- [15] LIU Z, WANG Y, CHENG Q, et al. Analysis of the information entropy on traffic flows [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18012-18023.
- [16] GAO Z, BAO M, CUI T, et al. Collision risk assessment for intelligent vehicles considering multi-dimensional uncertainties [J]. IEEE Access, 2024, 12: 57780-57795.
- [17] OH G, LEBLANC D J, PENG H. Vehicle energy dataset (VED), a large-scale dataset for vehicle energy consumption research [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 23(4): 3302-3312.
- [18] SARAIVA P. On Shannon entropy and its applications[J]. Kuwait Journal of Science, 2023, 50(3): 194-199.
- [19] CUI Z, QU C, ZHANG Z, et al. An adaptive interval many-objective evolutionary algorithm with information entropy dominance [J]. Swarm and Evolutionary Computation, 2024, 91: 101749.
- [20] ZHANG Y, WANG C, Yu R, et al. The ad4che dataset and its application in typical congestion scenarios of traffic jam pilot systems [J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(5): 3312-3323.
- [21] DE GELDER E, CATOR E, PAARDEKOOPE J P, et al. Constrained sampling from a kernel density estimator to generate scenarios for the assessment of automated vehicles[C]. Proceedings of the 2021 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops). IEEE, 2021.
- [22] WANG J, LU H, PLATANOTIS K N, et al. Gaussian kernel optimization for pattern classification[J]. Pattern Recognition, 2009, 42(7): 1237-1247.
- [23] ZYLIUS G. Investigation of route-independent aggressive and safe driving features obtained from accelerometer signals [J]. IEEE Intelligent Transportation Systems Magazine, 2017, 9(2): 103-113.
- [24] KARROUCHI M, NASRI I, RHIAT M, et al. Driving behavior assessment: A practical study and technique for detecting a driver's condition and driving style[J]. Transportation Engineering, 2023, 14: 100217.
- [25] ZHANG Y, CHEN Y, GU X, et al. A proactive crash risk prediction framework for lane-changing behavior incorporating individual driving styles [J]. Accident Analysis & Prevention, 2023, 188: 107072.
- [26] ZEINALI S, FLEPS-DEZASSE M, et al. Design of a utility-based lane change decision making algorithm and a motion planning for energy-efficient highway driving[J]. Control Engineering Practice, 2024, 146: 105881.
- [27] LI L, GAN J, JI X, et al. Dynamic driving risk potential field model under the connected and automated vehicles environment and its application in car-following modeling[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 23(1): 122-141.
- [28] TYAGI I. Threat assessment for avoiding collisions with perpendicular vehicles at intersections [C]. Proceedings

of the 2021 IEEE International Conference on Electro Information Technology (EIT). IEEE, 2021.

作者简介



曾超杨, 2021 年于成都大学获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为网联汽车智能决策与轨迹规划。
E-mail: S230301002@stu.cqupt.edu.cn.

Zeng Chaoyang received his B. Sc. degree from Chengdu University in 2021. Now

he is a M. Sc. candidate at Chongqing University of Posts and Telecommunications. His main research interests include intelligent decision-making and trajectory planning of connected vehicles.



刘平 (通信作者), 2012 年于华北电力大学获得学士学位, 2017 年于浙江大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为网联汽车轨迹规划决策与控制。

E-mail: liuping_cqupt@cqupt.edu.cn.

Liu Ping (Corresponding author) received his B. Sc. degree from North China Electric Power University in 2012, and Ph. D. degree from Zhejiang University in 2017. Now he is an associate professor in Chongqing University of Posts and Telecommunications. His main research interests include trajectory decision, planning and control of connected vehicles.