

# 基于改进行车风险场的自动驾驶汽车轨迹规划研究

卢宇航, 王 晨

西华大学汽车与交通学院, 四川 成都

收稿日期: 2026年3月22日; 录用日期: 2026年4月12日; 发布日期: 2026年4月23日

## 摘 要

在复杂的交通环境中, 准确建立行车风险模型并量化风险分布, 是评估自动驾驶安全性的关键, 也是系统实现类人决策的基础。然而, 现有的风险场模型在处理多种风险要素耦合以及适应动态场景时仍存在不足。为此, 本研究提出了一种融合多源风险要素的改进型行车风险场模型, 分别构建了动态交互风险场与静态约束风险场, 成功将行车风险转化为可以量化的空间分布场强。随后, 本研究将该模型深度嵌入到自动驾驶的换道决策框架中。系统能够在决策层完成实时的风险评估与路径优化, 从而有效应对复杂场景下的换道需求。最后, 仿真实验结果表明, 该改进模型能够显著降低车辆的碰撞风险概率, 并有效提升行驶效率。本研究为自动驾驶的决策与规划提供了一种兼具安全性与鲁棒性的解决方案。

## 关键词

自动驾驶, 风险场, 决策规划, 行车安全

# Research on Trajectory Planning for Autonomous Vehicles Based on Improved Driving Risk Field

Yuhang Lu, Chen Wang

School of Automobile and Transportation, Xihua University, Chengdu Sichuan

Received: March 22, 2026; accepted: April 12, 2026; published: April 23, 2026

## Abstract

In complex traffic environments, accurately establishing a driving risk model and quantifying risk

distribution is crucial for assessing the safety of autonomous driving, and it also serves as the foundation for the system to achieve human-like decision-making. However, existing risk field models still have deficiencies in handling the coupling of multiple risk factors and adapting to dynamic scenarios. To address this, this study proposes an improved driving risk field model that integrates multi-source risk factors. This model constructs a dynamic interactive risk field and a static constrained risk field, successfully transforming driving risks into quantifiable spatial distribution field intensities. Subsequently, this study deeply embeds this model into the lane-changing decision-making framework of autonomous driving. The system is capable of completing real-time risk assessment and path optimization at the decision-making level, effectively addressing lane-changing demands in complex scenarios. Finally, simulation experimental results show that the improved model can significantly reduce the probability of vehicle collisions and effectively enhance driving efficiency. This study provides a solution for autonomous driving decision-making and planning that combines safety and robustness.

## Keywords

Autonomous Driving, Risk Field, Decision-Making Planning, Driving Safety

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

增强汽车行驶安全性始终是自动驾驶技术发展的核心目标之一。研究表明, 驾驶技能和驾驶行为是导致交通事故频繁发生的主要因素[1]。驾驶技术能力的提升依赖长期训练, 但个体差异导致整体优化难度较大。加之驾驶员行为状态的不确定性显著影响交通安全, 使得从驾驶员层面提升行驶安全性面临多重挑战。而自动驾驶车辆可通过主动避障功能有效提升行驶安全性[2]。作为评估网联自动驾驶汽车(CAVs)行驶安全性的有效手段, 行车风险场对城市多车道场景中的交通冲突进行风险检测与评估, 对保障行车安全、减少城市交通事故具有重要现实意义。

关于风险场的应用, 国内外学者已有相关研究工作。风险场的研究受到人工势场的启发。1986年, 人工势场的概念被首次提出并应用于机器人路径规划, 此类研究起源于由 khatib 提出的基于人工势场概念的移动机器人轨迹规划方法[3]。受此思想的启发, 许多学者将势场理论推广到交通流研究领域, 并取得了一些重要的研究成果。NI 从交通的宏观与微观两个角度分别论证了势场在交通中的客观性与普遍性[4][5]。此外, Gao 等基于 khatib 建立的引力场和斥力场提出了一种基于机器学习的实时自主车辆控制器[6]。同时, 李林恒等通过引入加速度参数对既有安全势场模型进行改进, 并建立了安全势场跟驰模型[7]。

在传统势场理论的基础上, 王建强等根据物体属性不同建立了人一车一路闭环系统的行车风险场统一模型, 提出了行车风险场的概念, 并用实车对模型进行了验证。结果表明, 该模型可为复杂交通环境下的驾驶风险评估提供有效方法[8][9]。进一步地, Mullakkal-Babu F A 等人设计一种用于评估道路车辆所承担风险的方法, 在该方法中任何障碍物都被视为在主车的预测配置空间中公式化的有限量风险场, 驾驶风险估计是主车未来位置的风险场强度, 该风险场被公式化为碰撞概率和预期碰撞能量[10]。Li L 等人提出一种新的互联自动化车辆环境下的动态驾驶风险势能场模型, 该模型充分考虑了车辆加速和转向角的动态影响[11]。此外, 为了将人类驾驶策略嵌入智能驾驶系统, Zhao X 等人采用风险场理论对环境风险进行建模, 通过从 24 名人类驾驶员的驾驶数据中研究响应策略, 提出风险响应驾驶员模型[12]。接下来, Wang Y 等人提出一种新的驾驶干预系统, 用于驾驶员残疾条件下的自主避险, 包括紧急安全场的

定量风险评估模块和一个运动规划模块。紧急安全场包括道路边界、障碍物和目标位置, 在基于场的框架中, 每个元素都被建模为产生斥力场和引力场的单个风险源[13]。Teng C 等人基于驾驶风险场理论, 构建一个适用于多车跟车的跟车模型, 该模型将前方多辆车的驾驶信息纳入后方车辆驾驶状态的计算中, 对前方车辆的加速度变化高度敏感[14]。Liu X 等人提出一种用于周围车辆交互式轨迹预测的驾驶风险图集成深度学习方法, 该方法使用条件高斯分布来考虑运动不确定性, 构建驾驶风险图实现车辆-车辆和车辆-环境相互作用的统一和可解释表示, 并设计再学习模块获取周围车辆的精确轨迹预测。在 HighD 数据集对该方法进行了评估, 结果表明该方法对周围车辆的轨迹预测更加准确可靠[15]。Jiao X 等人提出基于边界的风险评估方法和相应的决策机制, 作为理解智能车辆整体风险分布的一种轻量级方法。将不同的环境元素建模为表示空间占用、语义类型和运动状态的统一环境边界, 根据以自车为中心的极坐标系中的环境边界, 对不同方向的风险进行分析, 并设置安全边界作为边界约束, 用于决策。实验结果证明, 与决策性能相似的表层密集相比, 该方法显著降低了计算负担[16]。

但是, 以前的模型有一些缺点。它们通常只能计算汽车在固定速度和固定位置时的危险。它们不能很好地反映汽车在运动中的真实危险。另外, 旧模型没有充分考虑交通规则和道德规范。它们也没有考虑汽车自己的速度、大小和性能。而且, 旧模型算出的危险只代表危险的大小, 不能表示危险的方向。这让汽车很难在复杂的路上做出准确的反应。

为了解决这些问题, 我们提出了一种改进的行车风险场模型。我们的模型有三个优点。第一, 我们建立了一个动态风险场。我们引入了虚拟质量这个概念。这让汽车可以实时、准确地计算移动中的危险。第二, 我们考虑了横纵向危险的差异。这能帮助汽车做出更安全的决定。第三, 我们结合了多种交通因素。我们不仅考虑了速度和距离, 还考虑了交通规则和汽车的大小。

## 2. 风险场模型

### 2.1. 风险场基本概念与特性

基于场论研究框架, 风险场作为描述交通环境中风险要素空间分布特性与动态演化规律的核心概念, 将行车风险抽象为具有空间依赖性的物理量, 其场强分布直接主导自动驾驶汽车的运动决策过程。该理论体系的构建借鉴了人工势场法的核心思想: 通过在障碍物周边构建斥力势场、目标点周边构建引力势场, 形成由合力驱动的复合场模型, 进而实现无碰撞路径规划的动态引导机制。

行车风险场具备六大核心特性: 其一, 客观性, 车辆行驶必然受道路及周边环境影响, 行车风险场通过量化手段客观呈现潜在危险; 其二, 普遍性, 交通事故频发背景下, 行车风险场全面覆盖各类道路场景风险; 其三, 可变性, 道路动态因子如车速、车距、驾驶员行为等变化, 促使行车风险场实时更新; 其四, 可预测性, 基于事故因果关系, 通过量化多因素, 借助数学模型与算法实现风险预测评估; 其五, 多源性, 运动物体动能场、静态要素势能场及驾驶员行为场等多源风险因素交织构成复杂风险场; 其六, 空间分布性, 风险大小与分布随时空差异显著, 指导驾驶员动态风险评估决策。这些特性使行车风险场成为评估行车安全、指导路径规划的重要工具。实际应用中, 通过构建行车风险场模型, 可对各类风险因素进行量化分析, 为驾驶员及自动驾驶系统提供精准的风险评估与决策支持。

行车风险场是由车辆行驶过程中的多种因素共同组成的, 包括人、车、路等因素, 具体见表 1。可将其分为两大类型: 由障碍物(含动态、静态实体)生成的动态交互风险场, 以及由道路环境要素构建的静态约束风险场。其中, 影响动态交互风险场的因素涵盖车型、机械性能、运动状态及其他道路使用者(如行人、自行车、三轮车等); 静态约束风险场的影响因素包括车道线类型、车道宽度及交通规则等。各交通主体基于自身属性生成特定的驾驶风险值, 并通过场力叠加效应实现矢量合成, 共同构成综合驾驶风险场。

**Table 1.** Factors to consider in two types of risk fields

**表 1.** 两类风险场考量因素

风险场类别	考量因素
动态交互风险场	坐标位置、速度、加速度、质量、尺寸、航向角
静态约束风险场	车道线类型、车道宽度、红绿灯、限速标牌

## 2.2. 动态交互风险场模型

### 2.2.1. 虚拟质量的引入与计算

在道路交通场景中, 任何可能对行车安全构成威胁的目标物, 无论处于静止或运动状态, 其潜在风险均与自身质量、物体类别及运动状态(尤其是速度参数)存在紧密关联。为实现对各类风险因素的系统性量化, 特引入虚拟质量这一概念进行统一度量。一般而言, 虚拟质量的量化值越高, 表明车辆与该物体发生碰撞时可能产生的损伤程度越严重。具体来看, 当物体类别相同时, 其质量与速度参数的数值越大, 碰撞过程中可能导致的最大损失量也会相应提升; 而当物体的质量与速度参数相同时, 不同类别的物体在碰撞中造成的损伤后果仍会存在差异。目标物的虚拟质量可通过公式(1)进行计算:

公式(1)中,  $M_k$  表示物体的实际质量,  $T_k$  表示物体的类型, 当物体类型为轿车时  $T_k = 1$ ,  $v_k$  表示第  $k$  个障碍物的速度。

$$M_k = m_k T_k (1.566 \times 10^{-14} v_k^{6.687} + 0.3345) \quad (1)$$

### 2.2.2. 动态交互风险场模型改进

针对自动驾驶车辆在复杂交通流中的轨迹规划与决策控制任务, 精确感知并量化周边交通参与者的潜在威胁构成了系统安全性的基石。相较于静态环境要素, 道路上的车辆和行人通过相对速度与空间位置的实时演变, 与自车产生动态交互风险。为了量化这种风险, 我们建立了一个统一的动态交互风险场模型。这个模型把道路上的动态元素都放到同一个空间里来计算。这样我们就能精确地衡量行车风险。在这个环境里, 运动的车辆和行人是路面上的主要危险源。它们产生的风险分布非常不规则。这些动态交通参与者的大小、速度、移动方向以及它们自身的质量, 都会共同影响风险的具体形态。

为了让模型更贴近真实情况, 我们对这些动态风险源设定了几个基础的假定条件: 其一, 风险势场在笛卡尔空间内需满足连续可微性, 避免出现奇异点, 以保障下游梯度优化算法的数值稳定性; 其二, 遵循危险源辐射的物理规律, 风险强度应随欧氏距离增加呈现单调衰减趋势, 并在无穷远处渐进收敛至零; 其三, 风险分布表现出显著的各向异性, 车辆速度的提升将沿运动方向延缓风险衰减, 扩大危险影响域, 而当速度降至 0 m/s 时, 模型应自适应退化为静态障碍物的空间占据风险; 其四, 考虑到车辆纵向与横向动力学控制特性的差异, 需对两个维度的风险传播机制进行解耦建模。基于以障碍车几何中心为原点的车辆坐标系(其中  $x$  轴与  $y$  轴分别对应车辆纵向与横向), 引入纵向衰减因子以刻画纵向风险的传播规律, 其解析表达式定义如下:

$$\delta_{x,k}(x, y, t) = \frac{\beta_{k,x}^{longi} \max\left(|X| - \frac{1}{2} L_k, 0\right)}{\alpha_{k,x}^{longi} v_{k,x}^{longi}(t) + 1} \quad (2)$$

式(2)中, 变量  $x, y$  标定车辆在世界坐标系下的绝对位置;  $L_k$  代表第  $k$  辆障碍车的物理长度。通过引入最大值函数  $\max$ , 确保了纵向相对间距非负, 且在车辆几何轮廓内部衰减因子恒定。参数  $\alpha_{k,x}^{longi}$  与  $\beta_{k,x}^{longi}$  分别量化了纵向速度与纵向间距对风险场形态的敏感度, 其取值依赖于车辆类型。  $v_{k,x}^{longi}(t)$  则为  $t$  时刻的瞬时纵向速度。基于此, 构建车辆纵向风险场强函数:

$$E_{dy, longi, k}(x, y, t) = \frac{KM_k R_k}{\delta_{x, k}(x, y, t) + 1} \quad (3)$$

其中, 常数  $k > 0$  为增益系数;  $M_k$  被定义为第  $k$  辆障碍车的虚拟质量, 反映其发生碰撞时的潜在动能危害;  $R_k$  为路况因子, 用于表征路面附着系数等环境约束。

遵循相同的物理逻辑, 横向风险场的构建充分考虑了车道保持与换道行为的交互特性。横向衰减因子  $\delta_{x, k}(x, y, t)$  定义为:

$$\delta_{y, k}(x, y, t) = \frac{\beta_{k, y}^{lateral} \max\left(|Y| - \frac{1}{2}W_k, 0\right)}{\alpha_{k, y}^{lateral} v_{k, y}^{lateral}(t) + 1} \quad (4)$$

此处,  $W_k$  指代第  $k$  辆车的物理宽度;  $\alpha_{k, y}^{lateral}$  与  $\beta_{k, y}^{lateral}$  为横向速度与横向间距的风险影响权重;  $v_{k, y}^{lateral}$  为横向速度分量。对应的横向风险函数表达式为:


$$E_{dy, lateral, k}(x, y, t) = \frac{KM_k R_k}{\delta_{y, k}(x, y, t) + 1} \quad (5)$$

为了在统一的度量空间内融合纵横向风险, 本研究采用欧几里得范数构建综合衰减因子  $\delta_{y, k}(x, y, t)$ , 实现了风险场在二维平面上的平滑过渡:

$$\delta_k(x, y, t) = \sqrt{\delta_{x, k}^2(x, y, t) + \delta_{y, k}^2(x, y, t)} \quad (6)$$

最终, 第  $k$  辆障碍车产生的总动态交互风险场表征为:

$$E_{dy, k}(x, y, t) = \frac{KM_k R_k}{\delta_k(x, y, t) + 1} \quad (7)$$



**Figure 1.** Comparative visualization of risk field topology under static and high-speed motion states  
**图 1.** 静止与高速运动状态下风险场拓扑结构的对比可视化

为验证上述模型的有效性, 图 1 模拟了典型工况下的单车风险场分布。设定障碍车中心坐标为(20, 5), 尺寸参数,  $W_k = 2\text{ m}$ , 虚拟质量  $M_k = 1820\text{ kg}$ , 路况因子  $R_k = 1$  (理想路面)。模型敏感度参数设定为:  $\alpha_{k,x}^{longi} = 6$ ,  $\beta_{k,x}^{longi} = 6$  及  $\alpha_{k,y}^{lateral} = 2$ ,  $\beta_{k,y}^{lateral} = 2$ 。通过对比静止状态 0 m/s 与运动状态 20 m/s, 可清晰辨识出高风险势能区随速度增加向车头前方大幅扩散的趋势, 这与高速行驶所需增加的纵向安全制动距离在物理意义上保持高度一致。

随后, 为了验证模型在复杂多车场景下的有效性, 我们设计了如图 2 所示的双向四车道仿真实验。该场景涵盖了四辆物理属性与运动状态各异的障碍车辆(见表 2), 从而形成了一个具有高动态特性的混合交通流环境, 用于分析叠加风险场的拓扑分布。在该仿真环境中, 设定路况因子  $R_k = 1$ , 且各方向的速度与距离影响权重参数保持与单车实验一致。




Figure 2. Schematic diagram of a two-way four-lane mixed traffic scenario configuration

图 2. 双向四车道混合交通场景配置示意图

Table 2. Configuration of vehicle parameters in simulation scenarios

表 2. 模拟场景中车辆参数的配置

Vehicle ID	Type	$L_k$ (m)	$W_k$ (m)	$M_k$ (kg)	(x, y)	$v_x$ (m/s)
1	Truck	10.500	2.50	12000	(150, 34)	15
2	Ego car	4.400	1.90	1350	(60, 42)	20
3	SUV	4.950	2.00	2100	(110, 38)	22
4	Car	4.200	1.70	1150	(30, 42)	28

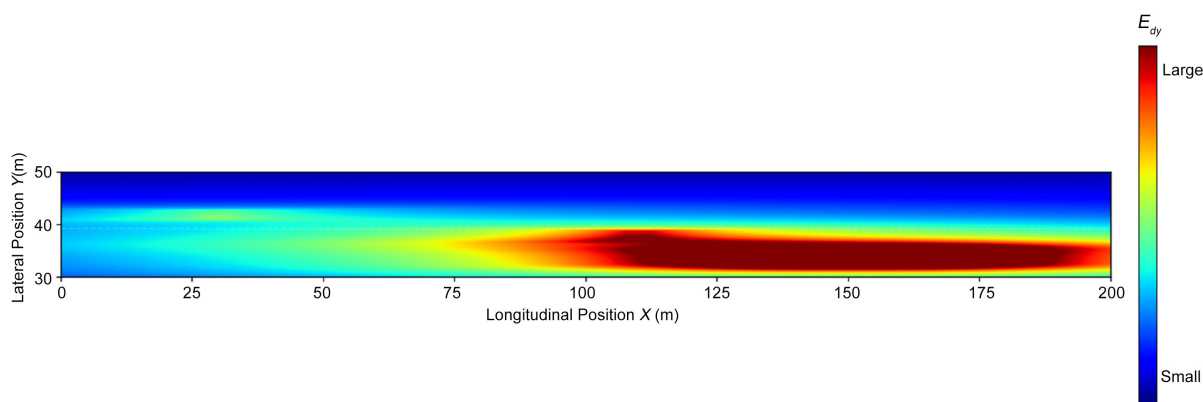


Figure 3. Thermodynamic diagram representation of unified risk potential intensity under complex traffic environment

图 3. 复杂交通环境下统一风险势能强度的热力图表征

图 3 展示了在多车交互场景下, 由障碍车辆产生的全局风险场分布。通过数值模拟, 可以清晰地观察到以下几个关键的场分布特性: 首先, 风险场的整体形态呈现为多个独立势场的非线性叠加。各障碍物周边的风险势能严格遵循物理空间的梯度衰减规律, 这与模型所设定的空间辐射规律高度吻合。其次, 也是该模型的核心价值所在, 即风险场的拓扑结构对交通参与者的物理属性表现出强敏感性。以障碍车

1 (重型卡车, 12,000 kg)和障碍车 4 (紧凑型轿车, 1150 kg)为例, 二者间的对比尤为显著: 尽管均处于动态行驶工况, 但重型卡车凭借其巨大的质量参数与几何尺寸, 在风险场中激发出一个峰值极高、空间覆盖范围大幅扩张的高风险区域。这一现象有力地验证了模型中虚拟质量因子  $M_k$  的物理有效性, 即模型能够精确量化不同类型车辆所带来的潜在威胁等级。

综上所述, 该风险场模型不仅能够描述车辆的运动学不确定性, 更重要的是, 它成功地对混合交通流中的风险进行了差异化表征。这种能力对于自动驾驶系统在真实、复杂的混合交通环境中制定风险感知型的运动规划与决策至关重要。

### 2.3. 融合道路几何特征与交通规则约束的静态风险场建模

在自动驾驶场景下, 静态风险源自道路本身的物理特性及交通法规的限定, 其风险特征在时空维度上往往具有较强稳定性。为精准量化此类风险, 本研究在车道标记模型的基础上构建了一个融合道路几何特征、实时路况及交通规则的多源约束静态风险场。该模型的构建逻辑可拆解为两个维度: 其一, 评估由道路曲率、坡度、附着系数及能见度等因素共同决定的基础道路风险  $R_a$ , 这些因素共同决定了车辆在特定位置  $(x_i, y_i)$  处的基础驾驶风险; 其二, 结合车道线、道路边界、交通信号等规则类约束, 最终构建出完整的静态风险场。该模型的数学表达式记为  $E_{st}$ :

$$E_{st} = E_{R2,a}(LT_a, R_a, D, r_{aj}, G_s) \quad (8)$$

其中  $LT_a$  为车道标志  $a$  的类型, 由当地交通法规确定, 例如车道标志  $a$  (白色实线) 的值大于车道标志  $b$  (白色虚线);  $D$  为车道宽度;  $r_{aj}$  为车道标识  $a$  与车辆质心的距离向量, 采用欧式距离计算;  $G_s$  为交通信号对风险的修正函数(图 4)。




Figure 4. Schematic diagram of lane markings  
图 4. 车道线示意图

$R_a$  用来表示由于自车位置  $(x_i, y_i)$  处的由道路  $a$  不同状况而导致的潜在驾驶风险。在这里, 潜在的驾驶风险主要指道路中的路况因素与车辆发生碰撞的可能性和严重程度。基础道路风险  $R_a$  定义为四种物理风险源(道路附着系数、道路坡度、道路曲率、能见度)的加权和, 记作:

$$R_a = w_1 \cdot f(C) + w_2 \cdot f(\mu) + w_3 \cdot f(\theta) + w_4 \cdot f(V) \quad (9)$$

其中  $C$  为路面曲率,  $\mu$  为路面附着系数,  $\theta$  为路面的坡度,  $V$  为能见度。  $f(C)$ 、  $f(\mu)$ 、  $f(\theta)$ 、  $f(V)$  分别表示  $C$ 、  $\mu$ 、  $\theta$ 、  $V$  的风险评价函数。  $w_1$  至  $w_4$  为权重系数并非固定不变, 可以通过专家系统标定, 或基于海量事故数据的回归分析, 针对不同驾驶场景(如高速公路或城市街道)进行自适应调整, 以反映各因素在特定情境下的重要性差异。

融合了道路几何、路况与规则的静态风险场强  $E_{st}$  最终被整合为一个矢量场, 其方向指向远离危险源, 大小则反映风险强弱:

$$E_{st} = LT_a \cdot R_a \cdot \left( \frac{D}{2} - |r_{aj}| \right)^{k_2} \cdot \frac{r_{aj}}{|r_{aj}|} \cdot g(S) \quad (10)$$

以  $E_{st}$  的模长为风险量化指标, 本研究生成了综合静态风险地图。在理想平直道路场景下(图 5), 静态风险场呈现出清晰的峡谷状空间分布: 道路中心区域的风险值最低, 对应由路面附着、坡度等基础道路条件决定的固有风险基底; 而靠近两侧车道线的区域风险值显著升高, 形成两条平行的风险山脊, 直观体现了车道边界对车辆行驶的刚性约束风险。




Figure 5. Schematic diagram of static risk field distribution under ideal straight track scenario

图 5. 理想直道场景下的静态风险场分布示意图

当场景切换至含弯道的真实道路(图 6)时, 风险场的形态变化进一步验证了模型的有效性。除车道线处的红色风险山脊仍清晰可见外, 整个弯道区域的风险基底显著抬高, 呈现出绿色至黄色的过渡色带。这一现象的核心成因在于弯道存在非零曲率  $C$ , 使得基础风险项  $R_a$  增大, 从而整体抬高了该区域的风险曲面, 与前文曲率风险函数  $f(C)$  的非线性增长特性完全吻合。通过对比图 5 与图 6 的风险场分布, 可验证本模型能够合理融合道路几何特征与边界约束, 生成与真实驾驶场景高度吻合的静态风险场。




Figure 6. Schematic diagram of static risk field distribution in a curved road scenario

图 6. 弯道场景下的静态风险场分布示意图

综上所述, 本研究已成功构建可量化描述静态交通环境的风险场模型。然而在真实的自动驾驶场景中, 风险并非仅源于道路几何、路面条件等静态环境, 车辆、行人等动态交通参与者带来的动态风险也会与静态风险相互交织、共同存在。因此, 如何对动、静态风险进行有效融合, 进而构建能够支撑车辆智能决策的统一风险视图, 将是本研究下一阶段的核心研究内容。

#### 2.4. 动静态多源风险协同耦合的综合场模型构建

前文建立了动静态风险场模型, 为行车风险评估提供了稳定基底。本节将聚焦于一个更复杂的问题:

如何将动态风险场  $E_{dy}$  和静态风险场  $E_{st}$  进行高效耦合。若直接对不同来源的风险场进行线性叠加, 易因多源低风险值的平均效应, 弱化对致命风险源的预警效能。为克服上述缺陷, 本文提出一种新型耦合策略: 首先识别当前场景下的主导风险源, 该风险源对行车安全起决定性作用, 需保障车辆对其具备优先感知与预警能力。当多类风险源同时存在时, 耦合形成的综合风险将显著高于单一风险场景。例如, 车辆在避让行人的同时紧邻路侧边缘, 此时的整体行车风险远高于仅存在行人或仅临近路侧的单一风险工况。针对此类多源耦合风险的量化计算问题, 本文引入模糊逻辑[17]方法实现求解。

该模块主要提取三个关键特征指标: 第一, 有效风险源的数量; 第二, 最大风险值与平均风险值的差值; 第三, 动态风险在总风险中的占比。基于上述三个指标, 本研究设计了三条核心模糊规则:

1) 单一主导风险场景: 当仅存在一个主要风险源时, 系统不进行耦合放大, 修正系数设定为 1.0。

2) 多源协同风险场景: 当存在多个中等强度以上的风险源时, 系统触发轻度耦合修正, 修正系数设定为 1.2。

3) 高危动态交互场景: 当存在大量风险源, 且动态风险占据主导地位时, 系统触发高危叠加修正, 修正系数设定为 1.5。

最终, 将该修正系数作用于主导风险场强, 我们便构建了经模糊修正后的综合风险场:

$$E_{\text{final}}(x, y, t) = E_{\text{max}}(x, y, t) \cdot k \quad (11)$$

这一结果既保留了模型对最高优先级风险的高度敏感性, 又通过模糊逻辑量化了多风险源并存时的复杂耦合效应, 从而实现了对环境风险更精准、更全面的刻画。

### 3. 基于行车风险场的轨迹规划算法仿真验证

当前, 自动驾驶领域的轨迹规划相关研究, 大多仅针对单车道避障或换道避障开展单一维度的算法设计。然而在复杂多变的实际交通场景中, 单一的避障规划方法难以同时满足车辆行驶的安全性与通行效率需求。例如: 当车辆不具备安全换道条件时, 若仅保持当前车道直行, 极易与前方障碍物发生碰撞; 反之, 若车辆仅局限于当前车道内执行避障操作, 未对相邻车道的交通风险进行预判与量化评估, 同样存在较高的碰撞事故风险。基于此, 本文提出一种避障轨迹规划策略。该策略以行车风险场的量化数值作为核心决策依据, 将车道选择、路径规划与速度规划纳入统一的决策框架进行全局协同优化, 在保障车辆行驶安全性的同时, 有效提升了全局通行效率。

#### 3.1. 基于五次多项式的轨迹生成

局部路径规划的核心在于生成满足道路规则、动力学约束以及避障需求的连续平滑曲线。在常用的插值曲线(如贝塞尔曲线、B 样条曲线与多项式曲线等)中, 综合考量算法的实时性与路径平滑度, 本文选用五次多项式曲线在 Frenet 坐标系下对自动驾驶汽车的局部运动路径进行建模。

在 Frenet 坐标系中, 设车辆相对于参考线的纵向位移为  $s$ , 横向偏移量为  $l(s)$  (规定向左偏移为正, 向右偏移为负)。轨迹规划的五次多项式模型可表示为:

$$l(s) = a_0 + a_1s + a_2s^2 + a_3s^3 + a_4s^4 + a_5s^5 \quad (12)$$

式中,  $a_0, a_1, a_2, a_3, a_4, a_5$  分别为五次多项式的待定系数。为了求解这些系数矩阵, 必须明确车辆在初始时刻的状态  $(s_0, l_0, l'_0, l''_0)$  以及期望在规划周期结束时达到的目标状态  $(s_1, l_1, l'_1, l''_1)$ 。其中,  $l'$  与  $l''$  分别代表横向偏移对纵向位移的一阶导数与二阶导数。当初始状态与末端状态确定后, 结合边界条件代入多项式方程, 即可实现矩阵求解, 获取具体的系数值。

在实际动态交通环境中, 为有效规避障碍物, 系统需在空间上进行离散采样以生成一组候选轨迹簇。

考虑到车辆行驶时需保持速度方向与参考线方向基本一致, 在采样时设定末时刻车辆的航向角正切值及其变化率均为 0。横向采样方面, 以车道中心线为参考, 结合结构化道路条件(如 3.75 m 的车道宽度), 采用固定间距  $\Delta d$  进行等距采样。这种方式能够在解空间的完备性与计算效率之间取得良好的平衡。纵向采样方面, 纵向距离对路径的横向偏移变化率有显著影响, 进而决定了车辆行驶的平滑性与乘坐舒适度。较高的车速要求更平缓的横向移动以减小横向加速度。为此, 本文提出了一种基于车速动态调整纵向采样间距的策略:

$$s = k \cdot v + s_{\min} \quad (13)$$

式中,  $s$  为动态纵向采样间距;  $v$  为车辆当前行驶速度;  $k$  为调节系数(本文取 2);  $s_{\min}$  为最小纵向采样间距(本文取 15 m)。该策略确保了在不同车速下, 系统均能自适应地调整纵向跨度: 高速时增大采样间距以减小横向偏移率, 低速时则保持较短间距以维持避障的敏捷性。

为了直观展示上述采样策略的效果, 图 7 呈现了基于该机制生成的候选路径簇。例如, 当车辆以 18 km/h 的较低速度行驶时, 根据动态调整策略计算得出的纵向采样长度较短(如图所示的 25 m)。在此状态下, 规划出的路径展现出了较大的横向偏移变化率, 呈现出较为陡峭的形态, 这充分保证了低速工况下的避障敏捷性。

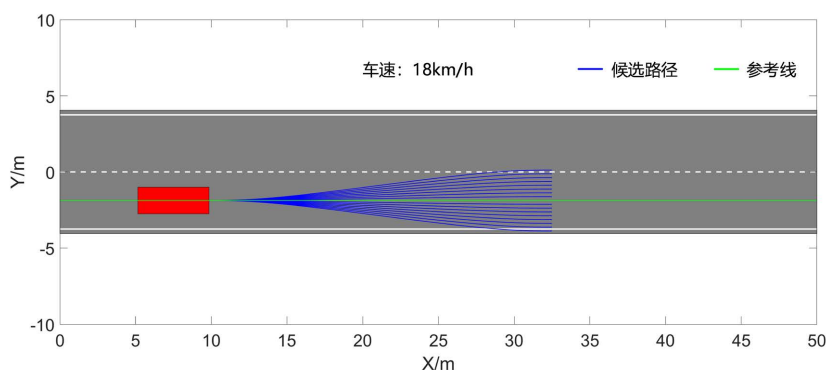


Figure 7. Fifth-order polynomial programming trajectory cluster  
图 7. 五次多项式规划轨迹簇

采用多项式采样方法生成一系列候选路径后, 必须对其进行严密的量化评估与筛选, 以确保控制模块接收到的最终路径既能保障绝对的安全性, 又能兼顾行驶的平顺性与连贯性。本文构建了多维度综合代价函数, 并结合车辆运动学约束, 设计了最优路径的筛选机制。综合考量了候选路径的安全性、偏移性、平滑性与连贯性。设  $C_i$  为第  $i$  条候选路径的总代价, 通过对各维度子代价值进行加权求和, 其具体表达式如下:

$$C_i = 0.5C_{safe,i} + 0.2C_{off,i} + 0.2C_{smooth,i} + 0.1C_{con,i} \quad (14)$$

式中,  $C_{safe,i}$ 、 $C_{off,i}$ 、 $C_{smooth,i}$  和  $C_{con,i}$  分别代表安全性、偏移性、平滑性与连贯性代价。

在获取各路径的总代价后, 算法按代价值由小到大进行排序, 并依次执行运动学约束校验。受车辆前轮转向机构限制, 候选路径的最大曲率  $K_{\max}$  必须满足最小转弯半径  $R_{\min}$  的物理约束:

$$K_{\max} \leq \frac{1}{R_{\min}} \quad (15)$$

系统优先提取总代价最小的路径。若该路径未发生碰撞、未非法越线, 且满足最大曲率约束, 则输出为当前周期最优路径; 否则予以剔除并顺延校验次优路径。若所有路径均不达标, 则触发重新规划机

制。

### 3.2. 模型应用示例

为验证上述基于行车风险场的轨迹规划算法的有效性与其可行性, 本文设计了专项仿真实验, 首先开展单车道避障场景的仿真测试(图 8)。该场景参数设置如下: 车道标准宽度为 3.75 m, 自车(Ego)初始行驶速度为 11.11 m/s; 自车左侧相邻车道设置两辆动态行驶车辆, 分别为 Obs1 与 Obs2, 其中 Obs1 位于自车后方 8 m 处, 行驶速度为 15 m/s, Obs2 位于自车前方 24 m 处, 行驶速度为 10 m/s; 自车当前行驶车道的前方 22 m 处, 设置静止障碍物 Obs3。




Figure 8. Schematic diagram of single-lane decision-making  
图 8. 单车道决策示意图

按照本文提出的策略, 自车先完成各车道的行车风险量化计算: 当前车道风险值为 198.94, 左侧车道因存在两辆行驶车辆, 风险值达 734.29。因本车道风险显著低于邻车道, 自车决策不换道; 同时针对本车道前方的静止障碍物, 系统启动单车道避障轨迹规划功能。

图 9 展示了后续 7 s 内两车道的风险值变化情况。结果显示, 本车道风险值先升高, 在自车绕开静态障碍物 Obs3 后逐渐降低; 相邻车道风险值则全程持续上升, 且在该时段内, 本车道风险值始终低于相邻车道。


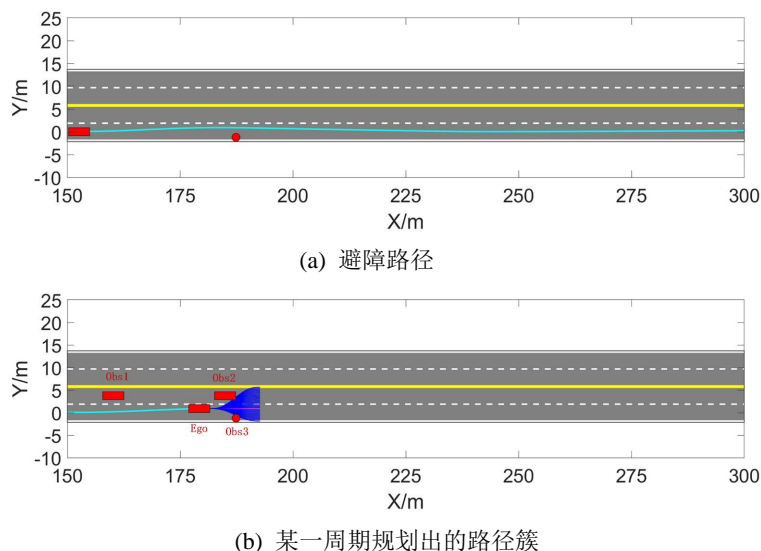



Figure 9. Subsequent risk value change curve for 7 s dual lanes  
图 9. 后续 7 s 双车道风险值变化曲线

本次轨迹规划的最终结果如图 10、图 11 所示。图 10(b)中, 蓝色线条为系统初步规划的多条备选轨迹簇, 系统基于风险场量化数值, 从中筛选出风险代价最小的最优轨迹(粉色线条)。自车沿这条最优安全轨迹(图 10(a)中青色实线)行驶, 成功绕避前方障碍物。图 11 为车辆行驶轨迹的曲率变化情况, 可见轨迹曲率幅值小、变化过程平滑, 说明规划出的轨迹既满足行车安全要求, 也符合车辆运动学约束与乘坐舒适性需求。




**Figure 10.** Simulation experiment results of obstacle avoidance in single lane  
**图 10.** 单车道避障仿真实验结果



**Figure 11.** Single lane obstacle avoidance trajectory curvature  
**图 11.** 单车道避障轨迹曲率

随后设置换道避障仿真场景(图 12), 场景基础参数为: 车道宽度 3.75 m, 自车初始速度 16.67 m/s; 自车左车道后方 5 m 处设置静止故障车 Obs1, 本车道前方 50 m 处设置低速行驶车辆 Obs2 (行驶速度 8.33 m/s)。



**Figure 12.** Schematic diagram of lane changing and obstacle avoidance scenario  
**图 12.** 换道避障场景示意图

与前述决策逻辑一致, 自车先完成两车道的风险值量化计算, 结果显示: 当前车道风险值为 129.63,

左侧车道风险值为 108.31。为保障换道安全, 本研究设定换道决策安全阈值为换道前最大风险值的 0.7 倍, 即 114.1。系统综合判断确认: 当前车道风险已超出安全阈值, 且左侧车道风险更低; 自车与前方慢车的 50 m 纵向间距, 大于系统计算的安全距离 43.64 m; 同时左侧车道线为虚线, 符合交通法规的换道要求。基于上述全部判定条件, 系统启动换道避障轨迹规划功能。

图 13 展示了后续 7 s 内两车道的风险值变化情况。受自车与前方慢车纵向间距持续缩小的影响, 本车道风险值快速上升, 而相邻车道风险值仅呈缓慢上升趋势。在该 7 s 观测时段内, 本车道风险值始终高于相邻车道, 表明自车的换道决策具备持续的安全执行窗口。




Figure 13. Subsequent risk value curve of 7 s dual-lane road  
图 13. 后续 7 s 双车道风险值变化曲线

本次换道的轨迹规划结果如图 14、图 15 所示。与单车道避障场景采用一致的优选逻辑, 系统从多条备选轨迹(图 14(b)蓝色实线)中, 基于风险场量化数值筛选出最优换道轨迹(粉色实线)。自车沿该轨迹(图 14(a)中青色实线)行驶, 安全平顺地完成向左换道。图 15 的曲率变化曲线显示, 换道过程中轨迹曲率幅值小、变化连续无突变, 充分说明基于行车风险场规划的换道轨迹平顺性优异, 可有效保障换道过程的安全与稳定。





Figure 14. Simulation test results of lane changing and obstacle avoidance  
图 14. 换道避障仿真测试结果



**Figure 15.** Characteristics of trajectory curvature change in lane changing and obstacle avoidance scenarios  
**图 15.** 换道避障场景轨迹曲率变化特性

#### 4. 总结

本文针对现有行车风险场模型在处理多风险要素耦合及动态场景适应性方面的不足, 提出了一种融合多源风险要素的改进型行车风险场模型。研究分别构建了引入虚拟质量且解耦纵横向风险的动态交互风险场, 以及融合道路几何特征与交通规则静态约束风险场, 并利用模糊逻辑有效解决了多风险源并存时的复杂耦合效应, 实现了对交通环境风险分布的精准刻画。在此基础上, 本文将该综合风险场模型深度嵌入到自动驾驶的轨迹规划框架中, 设计了兼顾单车道避障与换道避障的综合决策策略。仿真实验结果表明, 该系统能够实时、精准地量化复杂交通流中的潜在威胁, 并基于风险代价规划出安全、平滑的最优行驶轨迹。该方法在有效降低车辆碰撞概率、提升全局通行效率的同时, 充分满足了车辆的运动学约束与乘员舒适性要求, 为自动驾驶汽车在复杂场景下的安全决策与路径规划提供了一种兼具安全性与鲁棒性的有效解决方案。

#### 参考文献

- [1] 王庆昕. 考虑驾驶员特性的车辆行驶风险度评估方法[D]: [硕士学位论文]. 长春: 吉林大学, 2020.
- [2] 刘洋. 基于 MPC 的自动驾驶车辆局部避障路径规划与路径跟踪控制研究[D]: [硕士学位论文]. 西安: 长安大学, 2021.
- [3] Khatib, O. (1986) Real-Time Obstacle Avoidance for Manipulators and Mobile Robots. *The International Journal of Robotics Research*, **5**, 90-98. <https://doi.org/10.1177/027836498600500106>
- [4] Ni, D. (2011) A Unified Perspective on Traffic Flow Theory, Part I: The Field Theory. *ICCTP 2011: Towards Sustainable Transportation Systems*, Nanjing, 14-17 August 2011, 4227-4243. [https://doi.org/10.1061/41186\(421\)420](https://doi.org/10.1061/41186(421)420)
- [5] Ni, D. (2011) A Unified Perspective on Traffic Flow Theory, Part II: The Unified Diagram. *ICCTP 2011: Towards Sustainable Transportation Systems*, Nanjing, 14-17 August 2011, 4244-4263. [https://doi.org/10.1061/41186\(421\)421](https://doi.org/10.1061/41186(421)421)
- [6] Gao, K., Yan, D., Yang, F., Xie, J., Liu, L., Du, R., et al. (2019) Conditional Artificial Potential Field-Based Autonomous Vehicle Safety Control with Interference of Lane Changing in Mixed Traffic Scenario. *Sensors*, **19**, Article 4199. <https://doi.org/10.3390/s19194199>
- [7] 李林恒, 甘婧, 曲翎, 等. 智能网联环境下基于安全势场理论的车辆跟驰模型[J]. 公路学报, 2019, 32(12): 76-87.
- [8] 王建强, 吴剑, 李洋. 基于人-车-路协同的行车风险场概念、原理及建模[J]. 中国公路学报, 2016, 29(1): 105-114.
- [9] 吴剑. 考虑人-车-路因素的行车风险评价方法研究[D]: [硕士学位论文]. 北京: 清华大学, 2015.
- [10] Mullakkal-Babu, F.A., Wang, M., He, X., van Arem, B. and Happee, R. (2020) Probabilistic Field Approach for Motorway Driving Risk Assessment. *Transportation Research Part C: Emerging Technologies*, **118**, Article ID: 102716. <https://doi.org/10.1016/j.trc.2020.102716>
- [11] Li, L., Gan, J., Ji, X., Qu, X. and Ran, B. (2022) Dynamic Driving Risk Potential Field Model under the Connected and Automated Vehicles Environment and Its Application in Car-Following Modeling. *IEEE Transactions on Intelligent Transportation Systems*, **23**, 122-141. <https://doi.org/10.1109/tits.2020.3008284>

- [12] Zhao, X., He, R. and Wang, J. (2020) How Do Drivers Respond to Driving Risk during Car-Following? Risk-Response Driver Model and Its Application in Human-Like Longitudinal Control. *Accident Analysis & Prevention*, **148**, Article ID: 105783. <https://doi.org/10.1016/j.aap.2020.105783>
- [13] Wang, Y., Yang, S., Li, J., Xu, S. and Wang, J. (2023) An Emergency Driving Intervention System Designed for Driver Disability Scenarios Based on Emergency Risk Field. *International Journal of Environmental Research and Public Health*, **20**, Article 2278. <https://doi.org/10.3390/ijerph20032278>
- [14] Teng, C., Ligang, G., Zexu, W., Qin, S. and Hao, N. (2022) Car Following Model Based on Driving Risk Field for Vehicle Infrastructure Cooperation. 2022 6th CAA International Conference on Vehicular Control and Intelligence (CVCI), Nanjing, 28-30 October 2022, 1-6. <https://doi.org/10.1109/cvci56766.2022.9964837>
- [15] Liu, X., Wang, Y., Jiang, K., Zhou, Z., Nam, K. and Yin, C. (2022) Interactive Trajectory Prediction Using a Driving Risk Map-Integrated Deep Learning Method for Surrounding Vehicles on Highways. *IEEE Transactions on Intelligent Transportation Systems*, **23**, 19076-19087. <https://doi.org/10.1109/tits.2022.3160630>
- [16] Jiao, X., Chen, J., Jiang, K., Cao, Z. and Yang, D. (2024) Autonomous Driving Risk Assessment with Boundary-Based Environment Model. *IEEE Transactions on Intelligent Vehicles*, **9**, 642-655. <https://doi.org/10.1109/tiv.2023.3285762>
- [17] Wang, Y., Xu, D., Xie, Y., Tan, S., Zhou, X. and Chen, P. (2025) Hierarchical Decision-Making for Autonomous Navigation: Integrating Deep Reinforcement Learning and Fuzzy Logic in Four-Wheel Independent Steering and Driving Systems. 2025 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Hangzhou, 19-25 October 2025, 2718-2725. <https://doi.org/10.1109/iros60139.2025.11246015>