

基于本体的非结构化道路场景建模和 行为决策的方法研究^{*}

姚彬¹ 赵盼² 林玲龙² 杨名¹

(1. 安徽大学物理与光电工程学院 合肥 230601; 2. 中国科学院合肥物质科学研究院智能机械研究所 合肥 230031)

摘要: 本文章针对非结构化道路,自主车辆难以进行有效导航和决策规划的问题,提出了一种基于本体论进行驾驶场景建模与行为决策的方法。首先,建立了非结构化道路中各个元素的本体模型,其中利用八方位模型来描述道路场景中无人车和障碍物之间的位置关系。然后,将自主车辆中栅格地图的笛卡尔坐标系转换为Frenet坐标系,以组合弹簧模型为架构定义风险函数来评估车辆在当前场景行车的风险值。再将光电信息数据和先验驾驶知识进行融合,形成本体知识库。最后用Prolog推理机推理出最终的行为决策结果,而该结果需满足安全性和合理性评估。实验结果表明,在非结构化道路中,该方法在决策层面能给出更符合驾驶员行为的决策结果、在辅助规划路径方面也表现良好。

关键词: 无人驾驶;行为决策;本体;非结构化道路;八方位模型;组合弹簧模型

中图分类号: TN958.98; TP242.4 文献标识码: A 国家标准学科分类代码: 520.10

Research on unstructured road scene modeling and behavior decision-making based on ontology

Yao Bin¹ Zhao Pan² Lin Linglong² Yang Ming¹

(1. School of Physics and Optoelectronic Engineering, Anhui University, Hefei 230601, China;

2. Institute of Intelligent Machines, Chinese Academy of Sciences, Hefei 230031, China)

Abstract: In this paper, a method for driving scene modeling and behavior decision-making based on ontology is proposed to solve the problem that autonomous vehicles have difficulty in effective navigation and decision-making planning on unstructured roads. First, an ontology model of each element in the unstructured road is established, in which the eight-direction model is used to describe the positional relationship between the unmanned vehicle and obstacles in the road scene. Then, the Cartesian coordinate system of the grid map in the autonomous vehicle is converted into the Frenet coordinate system, and the risk function is defined with the combined spring model as the framework to evaluate the risk value of the vehicle driving in the current scene. Then, the photovoltaic information data and prior driving knowledge are integrated to form an ontology knowledge base. Finally, the Prolog inference engine is used to infer the final behavior decision result, which must meet the safety and rationality evaluation. Experimental results show that in unstructured roads, this method can give a decision result that is more in line with the driver's behavior at the decision level and also performs well in assisting path planning.

Keywords: unmanned driving; behavioral decision-making; ontology; unstructured road; eight-direction model; combined spring model

0 引言

随着自动驾驶技术的快速发展,自主车辆在交通系统

中的应用前景十分广阔。自动驾驶汽车的智能决策模块涉及3个子模块:轨迹预测、行为决策和运动规划^[1]而决策系统负责处理复杂、动态的交通状况,产生安全、合理、合法的

驾驶行为^[2]。

在结构化道路中,感知技术已经取得了许多进展,例如卢曼和朱世博^[3]提出了一种结合 OpenCV 和 YOLOv5 的车道线检测方法,展示了在复杂场景中提高检测准确性和实时性的可能性,但决策路径规划在这些复杂环境中的应用仍面临许多挑战^[4]。尤其是当前自动驾驶技术在非结构化道路场景下的表现面临严峻挑战,这些环境通常缺乏明确的车道标记和规则,因此需要更先进的决策和路径规划系统。针对这些挑战,研究人员提出了多种用于非结构化道路场景的建模与行为决策方法。现有的非结构化道路研究大致可分为 3 类:基于路径搜索算法、机器学习和基于规则与推理的系统。

在非结构化道路场景中,路径搜索算法发挥了至关重要的作用。传统的 A 星算法(A* algorithm, A*)由于其计算简洁、路径最优性和启发式引导,被广泛应用于路径规划。然而,标准的 A 星算法在处理复杂的非结构化环境时面临局限,如难以处理障碍密集的动态场景。为了改进 A 星算法,研究人员提出了多种变体。例如, Yang 等^[5]研究了一种将 A 星搜索算法与人工势场(artificial potential field, APF)方法协同集成的创新方法。此外, Wen 等^[6]提出了一种基于蒙特卡洛树搜索(monte carlo tree search, MCTS)的决策模型,应用于自主车辆的行为规划,展示了在动态和不确定性环境中的优越性,但其计算复杂度较高,限制了其在实时决策中的应用。

随着深度学习和强化学习的发展,这些方法已逐渐应用于自动驾驶行为决策。强化学习特别适用于解决具有长期规划目标的问题,例如徐雪松等^[7]提出的个体-协同触发强化学习方法,通过减少机器人间的通讯和计算资源,提高了多机器人系统在复杂环境中的决策效率。然而,该方法依赖于准确的环境模型,并且在面对高维状态空间时,仍可能面临收敛速度慢和计算负担大的问题,这限制了其在自动驾驶领域的广泛应用。

基于规则和推理的系统通过明确的规则集来定义行为决策,通常使用知识库和推理引擎。这类系统的优点在于其决策过程的透明性和可追溯性。例如, Armand 等^[8]提出了基于本体的框架,用于提高驾驶辅助系统(advanced driver assistance system, ADAS)的情境感知能力。而 Zhao 等^[9]介绍了一个基于本体的驾驶决策系统,该系统通过访问本体基础的知识库来做出驾驶决策,例如在无控制交叉路口和狭窄的双向道路上做出安全决策。然而随着驾驶场景和规则数量的增加,规则的组合会呈指数级增长。当知识库变得非常庞大时,系统在实时处理和决策方面会遇到困难^[10]。

尽管现有方法在非结构化道路场景中各有优劣,仍存在诸多局限性。例如,路径搜索算法在应对动态障碍时表现欠佳,深度学习模型依赖于数据质量,而基于规则的系统面临实时性问题。

针对这些挑战,本文提出了一种基于本体论的驾驶场景建模与行为决策方法。与现有的路径规划方法相比,本文的主要创新点在于添加了决策层方面的影响,且其实时性良好,其优势来源于:

非结构化道路场景建模:通过构建非结构化道路中各个元素的本体模型,并利用八方位模型来描述车辆与障碍物的空间关系。

推理机的引用:本文将栅格地图的笛卡尔坐标系转换为 Frenet 坐标系,并通过组合弹簧模型构建风险函数,评估车辆的行驶风险。然后,通过融合光电信息和先验知识形成本体知识库,并利用 Prolog 推理机生成最终决策,确保决策过程的安全性和合理性。

决策层的自适应性:通过不断完善本体知识库,本方法能够应对复杂多变的驾驶场景,使车辆在非结构化道路中具备一定成长性,从而在更广泛的条件下保持安全驾驶。

本文接下来的结构安排如下:第 2 节介绍系统的结构组成,概述八方位模型、组合弹簧模型和 Frenet 坐标系;第 3 节详细描述基于本体的非结构化道路建模与行为决策方法;第 4 节展示实际越野场景中该方法可行性实验和其与带目标偏向的 RRT* 路径规划算法(rapidly-exploring random tree star, RRT*)对比实验;第 5 节总结本文的贡献与未来工作。

1 相关工作

图 1 给出了决策系统结构示意图,其分为离线部分和在线部分。离线部分先用 protégé 软件编辑本体内容,包括术语框(terminology box, TBox)和断言框(assertion box, ABox)。TBox 主要用于定义本体中的概念(classes)和关系(properties),它描述了领域内的术语及其结构。ABox 主要用于存储具体的实例数据,描述特定个体及其属性和关系^[11]。生成 owl 的格式文件需要转换为 pl 文件类型,这样才符合 prolog 推理机需要的格式。文件的内容会转换为包含事实和规则的先验知识。在线部分是需要在实车上实时运行的,其运行逻辑为:首先从感知模块得到栅格地图、坐标信息(在需要时转换为 Frenet 坐标系)、全局路径等感知数据,再与导入的 pl 文件中的先验知识进行信息融合,得到当前场景下的断言内容,发送给 prolog 推理机,结合 pl 文件里的规则,最终输出合适的横向决策和纵向决策结果。其中信息融合是指当前驾驶场景下,组合弹簧模型风险函数得到需要的感知模块数据后进行风险评估,再结合八方位模型,得到确定的断言信息。例如:safeToLeft、hasFrontRightObstacle、hasrisk 等。

1.1 八方位模型

Jiang 等^[12]设计了一种基于八方位模型的避障算法,通过实时感知机器人周围的障碍物位置和移动情况,实现机器人在动态环境中的自主导航。耿新力等^[13]对城市环境下的语义建模也引用了八方位模型,很好的描述了障碍

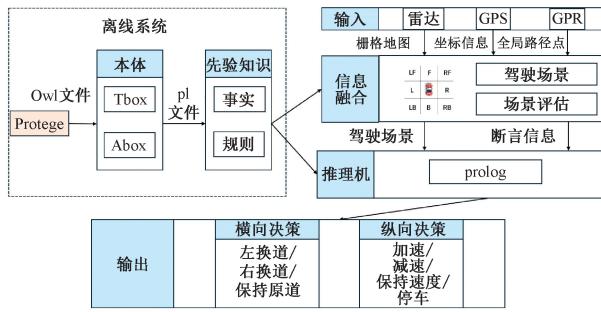


图1 系统结构图

Fig. 1 System structure diagram

物与车辆之间的位置关系。

在非结构化道路场景中,自主车辆需要实时感知和应对周围的动态变化,为了定量描述某一些变化,本文采用了八方位模型。如图2所示,八方位模型通过对车辆周围环境进行系统性分析,帮助车辆做出安全有效的决策。该模型将车辆周围划分为8个方位区域:前方(F)、后方(B)、左前方(LF)、右前方(RF)、左后方(LB)、右后方(RB)、左方(L)和右方(R)。

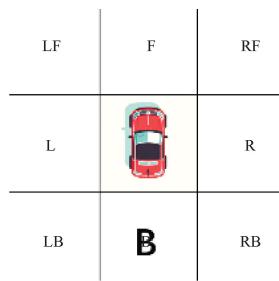


图2 八方位模型

Fig. 2 Eight-direction model

1.2 组合弹簧模型

图3(a)给出了组合弹簧模型的骨架,本文对该模型的应用主要在于车辆的纵向决策和横向决策。例如通过模拟车辆在不同方向上的受力情况(或者势场情况),根据风险函数S数值的大小调节车辆的速度,控制车辆在纵向决策上是加速、保持原速或减速。

众所周知,纵向驾驶风险与车头时距(time headway, THW)有关;在横向方向上,车辆通常对左右相邻车道上的道路使用者产生最显著的影响^[14]。可以设计一个椭圆范围的弹簧模型,如图3(b)所示,半长轴OA₂和半短轴OB₂的长度需要满足OA₂≥OB₂。v_j为车辆当前行驶的速度,B1B2为当前所有车道的总宽度。

因此,当某一障碍物i进入椭圆时,弹簧将压缩并储存弹性势能。可以得出:

$$F_{ji} = k \Delta x_{ji} \quad (1)$$

$$U_{ji} = \int_0^{\Delta x_{ji}} k d \Delta x_{ji} \quad (2)$$

式中: F_{ji} 表示车辆和之间的弹性力,k 是椭圆中的弹性系

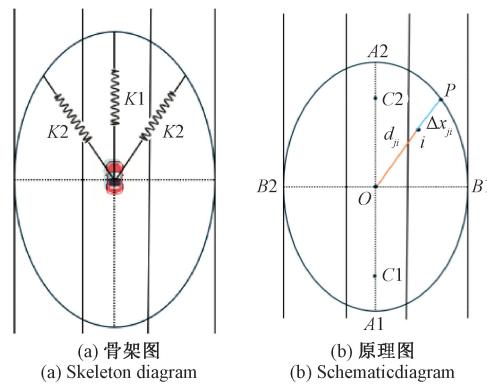


图3 组合弹簧模型架构图

Fig. 3 Combined spring model architecture diagram

数,Δx_{ji} 是弹簧压缩长度,U_{ji} 是弹性势能。

特别地,在非结构化道路场景下需要考虑地表材质的特殊性,不同的地表材质车辆的基本行进速率应该不同,因此障碍物对车辆产生弹簧力的大小也应该不同,式(1)中的k受地表材质的影响,根据地表材质的不同调整其大小值。

1.3 Frenet 坐标系

如图4所示,Frenet坐标系提供了一种描述车辆沿曲线路径运动的方法,通过切向量和法向量来描述车辆相对于路径的位置和运动状态^[15]。其中S表示沿着曲线的距离,L表示垂直于曲线的距离。下面是介绍将栅格地图中笛卡尔坐标系的坐标点转换为Frenet坐标系的步骤:

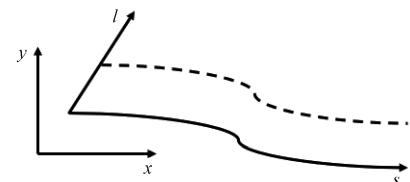


图4 Frenet 坐标系示意图

Fig. 4 Schematic diagram of frenet coordinate system

对于每一个障碍物在栅格地图中的位置(x,y),找到路径上距离该点最近的点。假设路径由一系列离散点表示为P_k(x_k,y_k),最近点可以通过计算障碍物位置(x,y)到路径上每个点的欧几里得距离,找到最小距离对应的点:

$$d_k = \sqrt{(x-x_k)^2 + (y-y_k)^2} \quad (3)$$

对于最近点P_k(x_k,y_k),计算障碍物位置(x,y)到路径在该点的切线方向上的投影。切线方向的单位向量可以通过路径点P_{k-1}(x_{k-1},y_{k-1})和P_{k+1}(x_{k+1},y_{k+1})来近似计算:

$$\mathbf{T} = \frac{(x_{k+1} - x_{k-1}, y_{k+1} - y_{k-1})}{\sqrt{(x_{k+1} - x_{k-1})^2 + (y_{k+1} - y_{k-1})^2}} \quad (4)$$

然后,计算从P_k(x_k,y_k)到障碍物位置(x,y)的向量:

$$\mathbf{D} = (x - x_k, y - y_k) \quad (5)$$

Frenet坐标系中的L坐标(横向距离)为:

$$L = \mathbf{D} \cdot \mathbf{T}^\perp \quad (6)$$

其中, \mathbf{T}^\perp 是切线方向向量 \mathbf{T} 的垂直向量, 可以通过旋转 \mathbf{T} 得到:

$$\mathbf{T}^\perp = (-\mathbf{T}_y, \mathbf{T}_x) \quad (7)$$

Frenet 坐标系中的 S 坐标(沿路径的距离)为路径上从起点到 P_k 的距离加上障碍物到 P_k 在切线方向上的投影距离:

$$S = S_k + \mathbf{D} \cdot \mathbf{T} \quad (8)$$

其中, S_k 为路径上起点到 P_k 的累积距离。

2 方 法

本节将按顺序介绍本文的部分工作内容, 包括驾驶场景语义建模和场景评估。驾驶场景语义建模是离线模块的工作, 使用 prolog 软件生成含有驾驶场景本体知识的 owl 格式文件, 作为事实转化为后续 prolog 推理机能调用的 pl 格式文件。而场景评估是结合安全性评估和合理性评估对应的 prolog 决策规则推理出决策结果, 然后根据决策结果做一些驾驶行为处理。

值得注意的是, prolog 决策规则来源于一般车辆行驶规则和驾驶经验, 形成场景-动作映射对。自动驾驶汽车的行为受到许多因素的影响, 如道路材质、周围障碍物、车辆性能等。为了满足决策的实时性要求, 本文选择了使用推理器。Prolog 是一种逻辑编程语言, 它只有 3 个语句: Fact、Rule、Question, 支持一元和二元逻辑表达式。深度优先搜索策略是 prolog 的基本推理策略。前言推理可以看作是基于事实和规则的智能数据库解决问题的过程。本文的推理器选择了 swi-prolog。它具有丰富的内置谓词和快速推理能力, 内置 prolog 推理引擎。更重要的是, 它提供了可以被外部程序方便调用的 c++ 类函数。

2.1 驾驶场景语义建模

本文用 protégé 软件构建的本体有 5 个主要类。如图 5 所示给出了本体的架构图。

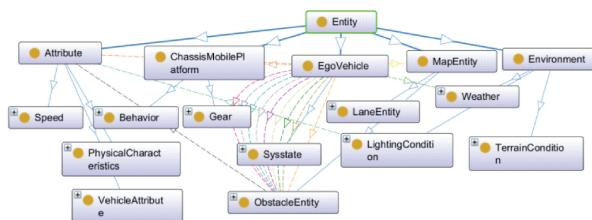


图 5 本体架构图

Fig. 5 Ontology architecture diagram

1) EgoVehicle.

EgoVehicle 代表自主车辆本身。车辆系统状态 Sysstate 归类于 EgoVehicle。而 Sysstate 分为 Regular 和 Interrupt。

2) ChassisMobilePlatform.

ChassisMobilePlatform 代表地盘机动平台。

ChassisMobilePlatform 分为 Gear 和 Behavior。而 Behavior 分为: LateralJunctionIntent 包括 GS、TL 和 TR; LateralOnRoadIntent 包括 LCL、LCR 和 LK; LateralOnRoadIntent 包括 ACC、DEC 和 KS。

3) Attribute.

Attribute 代表需要量化的常规属性。Attribute 分为: PhysicalCharacteristics 包括 Angle、Depth、Height、Length、Shape、Weight 和 Width; Speed 包括 CurrentVelocity、MaxAcceleration 和 MaxSpeed; MinAcceleration 包括 VehicleChassisHeight 和 VehicleChassisWidth。

4) MapEntity.

MapEntity 代表常见的地图实体。MapEntity 的子类有: ObstacleEntity 和 LaneEntity。ObstacleEntity 的子类为 DynamicObstacle 和 StaticObstacle。非结构化道路中可能没有车道的概念, 为了方便行车, 将 LaneEntity 设立为车道或虚拟车道。

5) Environment.

Environment 代表环境实体。Environment 的子类有: LightingConditions 包括 Lightbad 和 Lightgood; Weather 包括 Rainy、Foggy 和 sunny 等; TerrainConditions 包括 Rough 和 Smooth(如果感知模块条件允许, 可以分的更细节一些, 例如像泥路和砂石路面这种)。

Object properties 用于定义不同类之间的关系。对象属性连接两个实例, 通常用于表示一个实例与另一个实例的关联关系。EgoVehicle 与 ChassisMobilePlatform 有 hasPlatform 的属性, 与 Attribute 有 hasAttributes 的属性, 与 Environment 有 hasEnvironment 的属性。特别地, 以 EgoVehicle 为中心, 与 ObstacleEntity 有八个方向相关的属性。统一格式为: hasXXXObstacle, e. g. hasFrontRightObstacle。

Data properties 用于描述类的实例与数据值之间的关系。EgoVehicle 与 ObstacleEntity 之间有 hasdistanceToObstacle 属性, 数据类型为 double; 与 Sysstate 之间有 hassystemstate 属性, 数据类型为 boolean(true or false); 与 Attribute 之间有 hasHeight、hasMaxspeed 和 hasLength 等等, 数据类型为 double。而其他类, 例如 ObstacleEntity 与 Attribute 也拥有 hasHeight 等常规物理属性。

图 6 展示了越野场景下用语义建模的一例具体场景, 并且图 6 是对其语义描述。图 6 中共有 3 条虚拟车道实体 LaneEntity, 它们的实例为 lane1、lane2 和 lane3。无人车实体 EgoVehicle 行驶在 lane2 上, 前方有障碍物实例 obstacle1, 右前方有障碍物实例 obstacle2, 此时行驶的路面为土路。当前场景下, 上述定义的类、关系和属性等将作为先验知识加入到 TBox 中, 而道路实例作为先验知识加入到 ABox 中。

在场景建模之后, 本体的 OWL 格式文件作为事实被

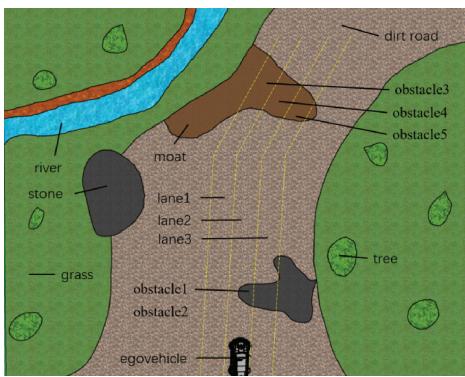


图 6 本体化实例

Fig. 6 Ontological example

进一步转换为符合 prolog 推理机格式的 pl 格式文件,以供后续使用。

2.2 场景评估

如图 6 所示,根据图中具体驾驶场景,先获得来自感知模块的数据,将栅格地图中障碍物、全局路径点等坐标值从笛卡尔坐标系转换为 Frenet 坐标系。全局路径点插值后在栅格地图中组成一条线。以这条线为中心,向左右各平移一段距离得到中间的虚拟车道。左右车道也由类似操作得到,车道的宽度大小根据需要进行调整。而将坐标转换为 Frenet 坐标系的目的是面对弯道时,也可以给组合弹簧模型寻找合适的椭圆范围。之后再进行安全性评估和合理性评估。安全性评估中将得到的风险值代入先验知识的规则中,匹配对应的规则得到评估结果。合理性评估中会根据当前驾驶场景对应的一些特殊规则进行合理性评估,匹配对应的规则得到评估结果。以上是本文的信息融合步骤,其得到的决策结果是由推理机综合推理出最终结果。

值得注意的是,本文忽略了传感器数据的不确定性。

1) 安全性评估

安全性是指左右车道能够为自动驾驶汽车完成变道行为提供安全的变道条件,或者前方区域能够安全行驶。本文根据组合弹簧模型定义了一套风险函数,再结合八方位模型用于安全性评估。

对于横向决策,即是否能够进行变道操作,定义有风险函数 S_1 :

$$S_1 = K_1 \times F_1 \times \sin(\theta_1) + K_2 \times (F_2 \times \sin(\theta_2) + F_3 \times \sin(\theta_3)) \quad (9)$$

其中, K_1, K_2 为常数系数,用于调整不同弹簧力对风险函数 S_1 的影响。 θ_1, θ_2 和 θ_3 分别为 F_1, F_2 和 F_3 对无人车的方向角。此时 $K_1 > K_2$, 因为中间车道对车辆的影响更大。

根据实验数据测量后,定义一个合适的阈值 S_{1th} 。当 S_1 小于阈值 S_{1th} 时,此时变道风险较小,可以考虑变道。同时再结合八方位模型有以下一条 prolog 规则案例:

decision (V, changeToRight) :- egoVehicle (V),

currentSpeed (V, CV), CV < 15, hasFrontObstacle (V, F), distanceToObstacle (F, DF), DF < 20, hasFrontRightObstacle (V, FL), hasLeftObstacle (V, "null"), hasFrontLeftObstacle (V, "null"), hasRisk (V, S1), S1 < S1th.

当满足规则 $decision (V, changeToRight)$ 的触发条件时,意味着此刻车辆向左变道的安全性评估通过。

参考图 6 实例图,这里选取车子行驶过程中遇到障碍物石块作为第一个场景,其组合弹簧模型应用示意图如图 7 所示,选取 lane1、lane2 和 lane3 三个虚拟车道中离车辆最近的障碍物点作为该车道内障碍物的位置(如点: C1、C2)。已知点 C1、C2 与车辆位置点 O 距离为 $DF_1 = 75.93$ m, $DF_2 = 69.05$ m, 弹簧弹性系数 $k = 100$ N/m, 而常数系数 $K_1 = 0.6, K_2 = 0.2$ 。无人车行驶在虚拟车道 lane2 中, lane1、lane2 和 lane3 车道前方的障碍物对无人车产生的弹性力为 F_3, F_1 和 F_2 , 而图 7 中虚拟车道 lane1 没有障碍物则该车道内 F_3 值等于 0。 F_1, F_2 (省略 F_3)与车辆形成的方向角为 $\theta_1 = 0.029$ rad, $\theta_2 = 0.785$ rad。那么根据风险函数 S_1 计算,得到当前场景下车辆进行向左变道的风险值 $S_1 = 391.19$ N。由于 S_1 小于阈值 S_{th} , 所以当前帧横向决策的向左换道安全性评估通过。

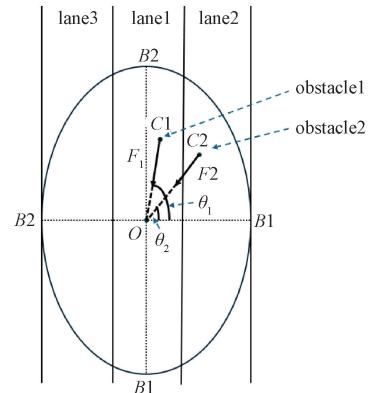


图 7 组合弹簧模型应用示意图

Fig. 7 Schematic diagram of combined spring model application

对于纵向决策,即车辆在单条道路上的加减速等,定义有风险函数 S_2 :

$$S_2 = K_3 \times F_1 \times \sin(\theta_1) + K_4 \times (F_2 \times \sin(\theta_2) + F_3 \times \sin(\theta_3)) + K_5 \times F_1 \times \cos(\theta_1) + K_6 \times (F_2 \times \cos(\theta_2) + F_3 \times \cos(\theta_3)) \quad (10)$$

其中 K_3, K_4, K_5, K_6 为常数系数并且 $K_3 > K_4, K_5 > K_6$, 因为中间车道对车辆的影响更大。

同样根据实验数据测量后,定义一个合适的阈值 S_{2th} 。

当 S_2 大于阈值 S_{2th} 时,此时判断车辆可能遇到状况,需要考虑减速。同时再结合八方位模型有以下一条 prolog 规则案例:

decision (V, decelerate) :- egoVehicle (V), currentVelocity (V,

CV), hasFrontRightObstacle (V, F), distanceToObstacle (F, DF), DF < 50, hasrisk (V, S2), S2 > S2th.

当满足规则 decision(V, decelerate) 的触发条件时, 意味着此刻车辆以当前速度行驶安全性评估不通过, 需要减速。

特别地, 前面提到的道路地表材质不一样会影响弹劲系数的数值, 比如图 6 中的土路换成砂石路, 那么车辆前行的风险会变大, 为了车辆稳定前行, 弹劲系数的值也应该相应增大, 具体值应该为多少, 需要根据具体的场景进行测量和调整。

相比于传统的碰撞时间评估 (time to collision, TTC) 方法去测量车辆碰撞概率, 组合弹簧模型的优势体现在其参数的多元化, 碰撞因素不仅仅和车辆与障碍物的距离相关。如果有其他影响因素, 也可以拟定额外的弹簧数量, 其产生弹簧力的大小与该因素相关。最终得到的风险函数的大小值 S 应该与每个弹簧产生的弹簧力 F 相关。

2) 合理性评估

对于当前非结构化道路的语义建模场景下, 车辆的驾驶行为是否合理体现在对其合理性评估是否通过。如图 6 中所示, 当前车辆的 3 条虚拟车道前方均出现凹障碍物 (壕沟), 其分别语义化 obstacle3、obstacle4、obstacle5。此时栅格地图中壕沟的宽度值大小不一定相等, 类似于责任敏感安全法则 (responsibility-sensitive safety, RSS)^[16] 中的最小安全距离评估, 将当前帧中壕沟出现的最大宽度值作为此刻壕沟的宽度值, 而自主车辆根据越障能力有跨壕沟的最大宽度阈值的限定, 将其比较大小可以判断车辆是否可以进行越障。其 prolog 规则为:

```
decision(V, go) :- egoVehicle(V), currentVelocity(V, CV), hasFrontObstacle(V, F1), distanceToObstacle(F1, DF), DF < 30, hasFrontRightObstacle (V, F2), hasFrontLeftObstacle (V, F3), ObstacleType (F, ConcaveOb), hasWide(ConcaveOb, W), W < Wth.
```

如果前方壕沟占据了 3 条车道并且宽度大于车辆支持越障的最大宽度, 此时应该考虑重新规划局部的路径, 使其能避过障碍物, 再根据新生成的局部路径, 重新生成虚拟车道进行决策。

以上例子仅针对类似壕沟这样类型的凹障碍物, 在非结构化道路场景中还会遇到形形色色的障碍物, 都可以用本文方法先进行本体语义建模, 找到车辆与障碍物的位置关系, 再根据可依据的逻辑完善 prolog 的规则库。

3) 结果处理

车辆在正常的行驶过程中, 是按照全局路径的轨迹行驶的, 并且每一帧都会实时用推理机生成当前帧的推理结果。以图 7 为例, 关于纵向决策结果的处理, 假设车辆按全局路径轨迹在 lane1 上向前行驶, 车辆前方和右遇到障碍物, 结果得到车辆需减速(加速)的断言后, 车辆会根据当前车速和当前车辆纵向风险函数 S_2 的数值大小动态调整车速, 尽量避免车辆从高速到低速的突变导致车辆行驶不稳,

影响行车安全。当得到停车指令时, 车辆也是先减速到低速再停车。至于横向决策结果的处理, 当结果得到可向左(向右)变道躲避障碍物的断言后, 系统会将原来的全局路径轨迹由中间车道向左移动到 lane3 上。然后在减速到安全变道速度的前提下, 车辆会沿换道轨迹短暂改变行驶路线, 达到避障的目的。

3 实验和讨论

3.1 实验平台

为了证明所提出的方法的可行性, 本文进行了几个场景的现场试验。实验平台如图 8 所示, 车辆是建立在阿克曼底盘的基础上, 配备了 GPS/IMU 用于车辆定位, 一个摄像机用于拍照记录, 以及一个 16 线激光雷达用于障碍物检测。使用的计算平台是研华工控机, 软件系统是在 ROS 操作系统上用 c++ 语言实现的。



图 8 实验平台

Fig. 8 Experimental platform

3.2 可行性实验测试

本文在图 9 和 10 所示两个不同的越野场景中测试了所提出的方法。选择以上两个场景是为了评估无人车能否根据前方区域状况, 根据决策系统得到符合预期的决策结果。

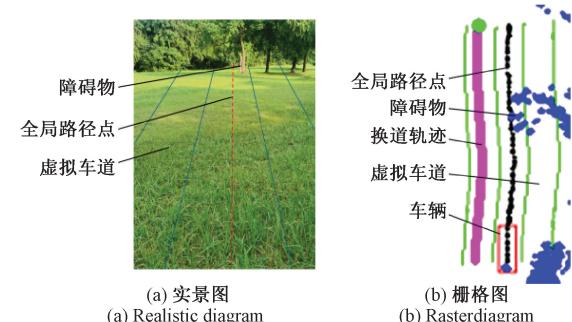


图 9 实验场景 1

Fig. 9 Experimental scene 1

图 9(a) 中车辆行驶到了如图所示的场景中, 可以看到有两个障碍物(树)在无人车的行驶路线上, 其中一个占据无人车正中间的虚拟车道, 另一个占据右边的虚拟车道。图 9(b) 是其对应实时的栅格地图。

图 10(a) 中车辆行驶到了一处长度能占据 3 条虚拟车道的障碍物(壕沟)处, 其宽度大小不一定相等。图 10(b)

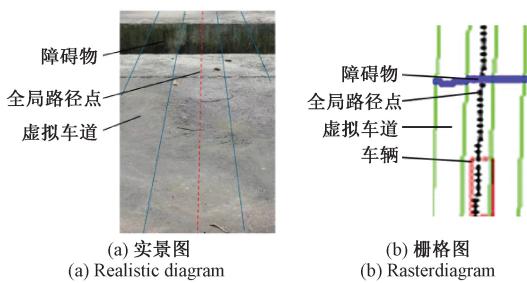


图 10 实验场景 2

Fig. 10 Experimental scene 2

是其对应实时的栅格地图。

图 11 和 12 显示了实验结果,图中的横主坐标轴是系统运行的帧数,纵主坐标轴是计算得到的风险值 S 值,次坐标轴是系统做出的决策结果 decision。如图所示不同线型分别表示不同帧数下的 S_1 值、 S_2 值、纵向决策、横向决策。次坐标轴中纵向决策的 1 表示加速 Acc,2 表示保持原速 Keep,3 表示减速 Dec,4 表示停车 Stop。横向决策的 1 表示保持车道,2 表示左换道,3 表示右换道。

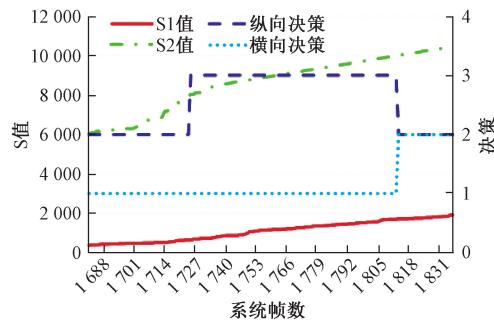


图 11 实验结果 1

Fig. 11 Experimental results 1

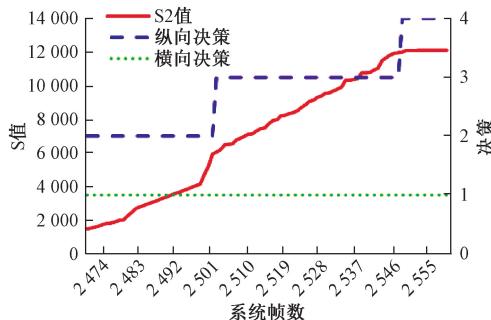


图 12 实验结果 2

Fig. 12 Experimental results 2

图 11 描述了车辆在匀速运动过程中到检测到正前方和右前方有障碍物,因为距离障碍物较远, S_2 风险值并不高,所以先保持原速行驶。当车辆与障碍物到达一定距离后 S_2 值大于设定的阈值 S_{th1} 开始减速,直到减速到满足换道的速度,然后保持该速度匀速行驶。当车辆与正前方障碍物之间的距离到达一定距离时, S_1 风险值小于设定的阈值 S_{th2} ,正好满足换道条件,做出向左换道的横向决策并生成了换道轨迹。整个过程是一个躲避障碍物的过程,根据实验场景 1 图 9(b)和图 11 的数据结果来看,车辆完成了预期的决策目标,执行了由减速到匀速向左换道的决策,保证了车辆安全。

图 12 描述了车辆在匀速运动过程中到检测到左前方、正前方和右前方有障碍物,因为距离障碍物较远, S_2 风险值并不高,所以先保持原速行驶。当车辆与障碍物到达一定距离后 S_2 值大于设定的阈值 S_{th1} 开始减速,减速过程中测得壕沟的最大宽度值大于小车能通过阈值大小。当 S_2 值大于设定的另一阈值 S_{th3} 时,触发了停车规则, S_2 的值不再增加。以上是纵向决策,横向决策上,因为前方 3 条道路都被障碍物占据,经判断无法通过换道操作躲避障碍物,所以没有生成换道轨迹。根据实验场景 2 图 10(b)和图 12 的数据结果来看,车辆完成了预期的决策目标,执行了由匀速到减速和由减速到停车的决策,保证了车辆安全。

3.3 对比实验测试

为了评估本文提出的基于本体论的决策方法在路径规划层面的作用,本文选择了与传统的带目标偏向的 RRT* 算法做对比实验。实验评估标准选取最小障碍物距离和避障路径的曲率两项关键指标:其中最小障碍物距离是指车辆行驶过程中与障碍物的最近距离,该指标直接影响行车安全性,较小的最小障碍物距离意味着更高的碰撞风险;路径曲率用于评估路径的平滑性,曲率较大的路径可能会导致车辆转弯过急并增加控制难度。

实验在两个非结构化道路场景中进行,一个为直道,另一个为弯道。实验仅包含静态障碍物,这些障碍物被放置在可通行区域中全局路径点的路线上。实验中,分别采用 RRT* 算法和本文提出的基于本体论的决策方法进行路径规划(换道)。两种方法的实验条件完全相同,车辆从同一初始位置出发,选取同样的全局路径,要求避开障碍物到达目标位置后方完成避障任务,图 13 展示了两种道路中,两种不同方法生成的对应栅格地图和一些路径信息等。

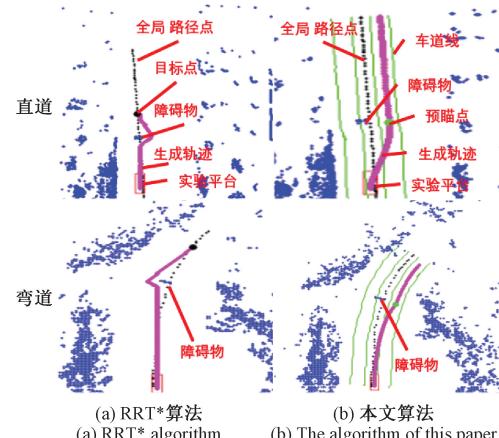
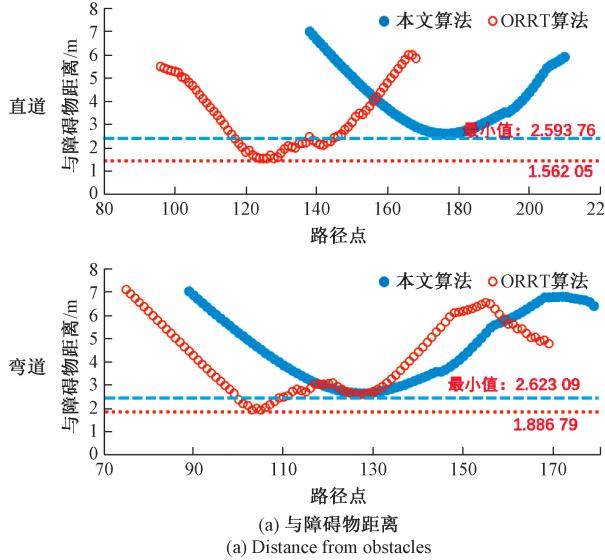


图 13 实验场景 3

Fig. 13 Experimental scene 3

图 14 记录了实验结果,其展示了两种方法在直道和弯道两种场景下生成的路径点对应与障碍物的距离和路径曲率。通过观察图中左上和左下两幅表格,发现在直道和弯道场景中,RRT* 算法生成的路径点最小障碍物距离分别为 1.562 05 和 1.886 79 m,而本文算法分别为 2.593 76 和 2.623 09 m,所以本文的方法在保障车辆行驶安全方面有



(a) 与障碍物距离
(a) Distance from obstacles

一定的效果。再观察图中右上和右下两幅表格,发现在直道和弯道场景中,RRT* 算法的路径曲率跳动性很大,而本文算法对应的路径曲率要更加平滑。因为 RRT* 算法在生成新的路径点时本身具有随机性,虽然加入了带目标偏向的模块,效果仍然不是很理想。

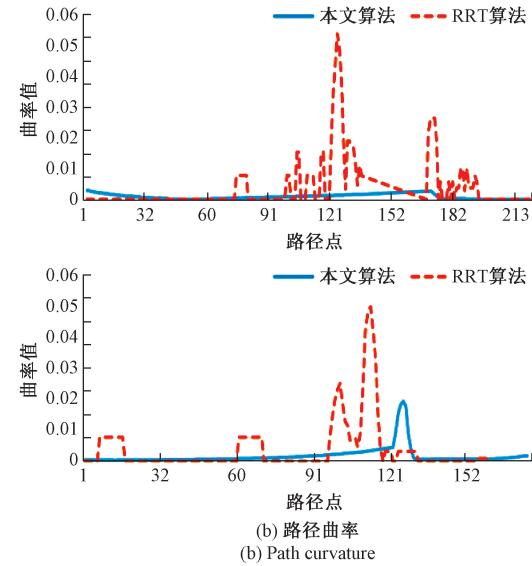


图 14 实验结果 3

Fig. 14 Experimental results 3

值得一提的是,RRT* 算法可以通过调整拓扑路径点的步长、目标偏向等一系列参数来调整生成的路径,使其能与障碍物保证一个安全距离并且生成的路径曲率较稳定。然而这会影响算法运行的耗时,从而对系统的实时性产生巨大影响。

此外在实验过程中,如图 13 中直道场景中,实验平台的左侧障碍物偏多,右侧较为空旷。根据驾驶员驾驶经验来说,此时向右进行绕障更优,而因为 RRT* 算法的随机性,有时会生成向左绕障的行为,这不是一个好的表现。而本文的方法则可以根据驾驶员驾驶经验,在本体知识库中定义这一规则,从而做出更正确的决策倾向,路径规划也会更合理平滑。

根据实验结果表明,实际非结构化道路场景中,基于本体论的决策方法在最小障碍物距离和路径曲率两个关键指标上均优于传统 RRT* 算法,证明了其在非结构化道路环境下具有更高的安全性和有效性。这表明,结合知识库和实时数据的决策框架可以更好地应对复杂多变的道路状况,为路径规划层做出贡献。

3.4 前景

本文的工作中有发展空间的工作包含:提高传感器数据的准确性、动态障碍物的行为预测和处理非结构化道路场景中更多样化的障碍物和地形等等。期待基于知识的推理决策模型在自动驾驶领域未来会发挥更大的作用,它

的可靠性和可塑性是大家所需要的。

4 结论

本文介绍了一种针对非结构化道路场景,基于本体论进行驾驶场景建模与行为决策的方法。本文使用本体对驾驶场景进行建模,并构建一个由先验知识的知识库。使用八方位模型描述车辆与障碍物位置关系,用组合弹簧模型结合对应的风险函数进行安全性和合理性评估,以改善决策。Prolog 推理器用于获得合理的决定。现场测试表明,本文的方法能够给出预期的决策并满足实时性要求。该方法可作为高级驾驶辅助系统、高级自动驾驶系统等众多自动驾驶应用的决策规划模块。

参考文献

- [1] China society of automotive engineers and national innovation center of intelligent and connected vehicles, annual report on the development of China intelligent connected vehicle industry(2022)[M]. Beijing: Social Science Academic Press(China), 2023.
- [2] HUANG L, LIANG H W, YU B, et al. Ontology-based driving scene modeling, situation assessment and decision making for autonomous vehicles [C]. 2019 4th Asia-Pacific Conference on Intelligent Robot Systems, (ACIRS), 2019.

- [3] 卢嫚,朱世博. 基于OpenCV和YOLOv5的车道线检测与识别[J]. 国外电子测量技术, 2024, 43(6): 134-142.
- LU M, ZHU SH B. Lane detection and recognition based on OpenCV and YOLOv5 [J]. Foreign Electronic Measurement Technology, 2024, 43(6): 134-142.
- [4] WANG N, LI X, ZHANG K H, et al. A Survey on path planning for autonomous ground vehicles in unstructured environments [J]. Machines, 2024, 12(1):31.
- [5] YANG Y L, LUO X Y, LI W, et al. AAPF*: A safer autonomous vehicle path planning algorithm based on the improved A* algorithm and APF algorithm [J]. Cluster Computing, 2024: 11393-11406.
- [6] WEN Q F, GONG ZH Y, ZHOU L F, et al. Monte-carlo tree search for behavior planning in autonomous driving[J]. ArXiv preprint arXiv:2310.12075, 2023.
- [7] 徐雪松,曾智,邵红燕,等. 基于个体协同触发强化学习的多机器人行为决策方法[J]. 仪器仪表学报, 2020, 41(5):66-75.
- XU X S, ZENG ZH, SHAO H Y, et al. Multi-robot behavior decision making method based on individual-collaborative trigger reinforcement learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 67-75.
- [8] ARMAND A, FILLIAT D, IBAÑEZ-GUZMAN J. Ontology-based context awareness for driving assistance systems [C]. IEEE Intelligent Vehicles Symposium, 2014:227-233.
- [9] ZHAO L H, ICHISE R, LIU ZH, et al. Ontology-based driving decision making: A feasibility study at uncontrolled intersections[J]. IEICE Transactions on Information and Systems, 2017,100(7):1425-1439.
- [10] LIU R, FU R, XU K, et al. A review of knowledge graph-based reasoning technology in the operation of power systems [J]. Applied Sciences, 2023, 13(7): 4357.
- [11] KAZAKOV Y, KROTZSCH M, SIMANCIK F. The incredible ELK: From polynomial procedures to efficient reasoning with EL ontologies[J]. Journal of Automated Reasoning, 2014, 53(1): 1-61.
- [12] JIANG L, ZHAO P CH, DONG W, et al. An eight-direction scanning detection algorithm for the mapping robot pathfinding in unknown indoor environment[J]. Sensors (Basel, Switzerland), 2018, 18 (12): 4254-4254.
- [13] 耿新力. 城区不确定环境下无人驾驶车辆行为决策方法研究[D]. 合肥:中国科学技术大学, 2017.
- GENG X L. Research on behavior decision-making approaches for autonomous vehicle in urban uncertainty environments [D]. Hefei: University of Science and Technology of China, 2017.
- [14] SUN D, ELEFTERIADOU L. Lane-changing behavior on urban streets: An “in-vehicle” field experiment-based study[J]. Computer-Aided Civil and Infrastructure Engineering, 2012, 27(7): 525-542.
- [15] GU T Y, DOLAN J M. On-road motion planning for autonomous vehicles [C]. Intelligent Robotics and Applications: 5th International Conference, 2012: 588-597.
- [16] MOBILEYE. Responsibility-sensitive safety(RSS): A model for safe autonomous driving [EB/OL]. Mobileye, 2017[2024-06-24].

作者简介

姚彬,硕士研究生,主要研究方向为智能移动机器人的决策与规划。

E-mail:1053391150@qq.com

赵盼(通信作者),博士,硕士生导师,主要研究方向为智能移动机器人的决策与规划。

E-mail:pzhao@hfcas.ac.cn

林玲龙,博士,副研究员,主要研究方向为智能移动机器人感知与决策、装备智能化无人化等关键技术。

E-mail:linll@iim.ac.cn

杨名,教授,博士生导师,主要研究方向为量子信息、量子计算(量子人工智能)、量子光学。

E-mail: mingyang@ahu.edu.cn