

自动驾驶汽车视野遮挡场景潜在风险评估

王登贵¹, 傅卫平^{1,2†}, 周劲草¹, 高志强¹, 宋清源¹

(1. 西安理工大学 机械与精密仪器工程学院, 陕西 西安 710048; 2. 西安外事学院 工学院, 陕西 西安 710077)

摘要: 视野遮挡区域的潜在风险对自动驾驶汽车的行驶安全提出了极大挑战. 面对难以准确有效地预测、评估潜在风险这一困难, 本文提出了一种基于“知识图谱+逻辑推理+贝叶斯推理”的潜在风险评估方法, 建立了潜在风险预判模型和潜在风险概率评估模型. 潜在风险预判模型通过构建“城市道路驾驶场景知识图谱”描述了场景中实体与实体间的交互关系, 并对场景描述信息进行语义转换, 采用SWI-Prolog推理机推断当前场景是否存在潜在风险; 潜在风险概率评估模型基于贝叶斯网络实现对潜在风险的概率评估. 通过现场实验验证, 所提方法对潜在风险的推理效果与人类驾驶员推理效果相似, 甚至可弥补人类未及时推理出潜在风险的过失. 方法适用于城市复杂道路交通, 风险评估结果能为自动驾驶或辅助驾驶的行为决策提供有效依据, 具有潜在应用价值.

关键词: 自动驾驶汽车; 知识图谱; 贝叶斯网络; 逻辑推理; 潜在风险评估

引用格式: 王登贵, 傅卫平, 周劲草, 等. 自动驾驶汽车视野遮挡场景潜在风险评估. 控制理论与应用, 2023, 40(6): 1023 – 1033

DOI: 10.7641/CTA.2022.20178

Potential risk assessment of vision-occluded scenarios for autonomous vehicles

WANG Deng-gui¹, FU Wei-ping^{1,2†}, ZHOU Jin-cai¹, GAO Zhi-qiang¹, SONG Qing-yuan¹

(1. School of Mechanical and Precision Instrument Engineering, Xi'an University of Technology, Xi'an Shaanxi 710048, China;

2. School of Engineering, Xi'an International University, Xi'an Shaanxi 710077, China)

Abstract: The autonomous vehicles safety is challenged by the potential risks arising from the visually occluded areas. A new method of potential risks assessment is put forward based on “Knowledge Graph + Logical Reasoning + Bayesian Reasoning” in the face of difficult to accurately and effectively predict and assess such potential risks, a potential risk prediction model and a potential risk probability inference model are constructed in the paper. The potential risk prediction model describes the interaction between driving entities by constructing the knowledge graph of urban scenarios for autonomous driving, and then infers whether there are potential risks during driving with SWI-Prolog inference engine after the description is semantic transformed; The potential risk probability reasoning model can quantify potential risks by inferring the probability of such risks replying on Bayesian Network. The field experiment prove that inference and assessment of potential risks conducted by the proposed method is similar to that conducted by human drivers, and can even compensate for human driver's unawareness of potential risks. The method is applicable to complex urban traffic. The results of risk assessment have potential application value as they can provide effective basis for the behavioral decision-making of the automatic driving system.

Key words: autonomous vehicles; knowledge graph; Rayesian network; logical reasoning; potential risk assessment

Citation: WANG Denggui, FU Weiping, ZHOU Jincai, et al. Potential risk assessment of vision-occluded scenarios for autonomous vehicles. *Control Theory & Applications*, 2023, 40(6): 1023 – 1033

1 引言

在复杂混合的城市交通环境下, 自动驾驶汽车仍面临诸多安全问题, 使得其全面进入商业应用仍存在较大的障碍, 一些研究表明道路环境风险评估对于提

高自动驾驶安全具有重要意义^[1-2]. 大多数自动驾驶风险评估方法均是针对环境信息完全感知的情况, 而自动驾驶技术所遇到的一个更大挑战是, 其感知系统可能由于视野遮挡而不能检测到其他交通参与者, 例

收稿日期: 2022-03-12; 录用日期: 2022-08-18.

†通信作者. E-mail: weipingf@xaut.edu.cn; Tel.: +86 13186186562.

本文责任编辑: 赵冬斌.

陕西省自然科学基金项目(2022JQ-546), 国家自然科学基金青年科学基金项目(52005401)资助.

Supported by the National Natural Science Foundation of Shaanxi Province (2022JQ-546) and the Natural Science Foundation of China (52005401).

如“鬼探头”场景等,已成为近几年受到更多关注的新课题^[3-4]. 本文以典型的城市道路交通环境为背景,提出一种基于“知识图谱+逻辑推理+贝叶斯推理”的自动驾驶视野遮挡潜在风险评估方法. 文中视野遮挡潜在风险(以下简称潜在风险)是指自主车辆在当前可行驶区域内行驶时,有可能有其他交通参与者(如行人、车辆等)从自主车辆视野遮挡区域进入到当前行驶区域,从而可能导致无法准确预知的潜在冲突.

相关工作:关于车辆运动的风险评估方法可归纳为两类,即确定性方法和概率方法^[5]. 确定性方法^[6]的优点是能够对简单场景下的风险威胁准确评估,然而,在复杂场景下却表现出较差的性能,并且对输入数据的不确定性不能很好地建模. 概率方法^[7-9]能够考虑宏观交通环境的上下文语义信息对潜在风险的影响,适用于具有视野遮挡场景下的风险评估. 国内相关研究多数只是针对道路交通环境中的显性风险评估,商伟超^[9]提出了基于静态障碍物的潜在风险概率评估模型,能够使自动驾驶汽车实现主动避障,但这种方法较为保守. 国外早期很多风险评估模型是从跟踪的角度解决了遮挡问题^[10-11],虽然这些模型可以跟踪进入遮挡区域的丢失目标,但它们都需要至少一次检测才能开始跟踪. 随着深度学习模型在人工智能领域的广泛应用,基于数据驱动的方法在自动驾驶风险评估领域得到了大量的应用^[12-13],该方法在数据规模较大的情况下表现较好. 但是,只是根据海量的数据来对模型进行训练,存在着不可解释性(黑箱特征),导致在一些情况下可能发生误判等情况^[4]. 部分可观测马尔可夫决策过程(partial observable Markov deci-

sion process, POMDP)是处理不确定性决策问题的常用方法,可以隐式地处理概率遮挡问题^[4,7]. 然而,为了易于计算,状态空间的减少限制了它们的适用性,特别是在实时高速驾驶中. 近期工作^[14]利用可达性分析,根据当前传感器观测结果,在整个前向可达区域生成无碰撞轨迹. 然而,这种方法对智能体的实时计算能力提出了更高要求,尤其是在复杂的城市道路交通场景中.

值得欣喜的是,知识图谱(knowledge graph, KG)在自动驾驶领域的最新应用^[15-16],为研究自动驾驶汽车潜在风险评估提供了有价值的途径. 目前类似人类通过环境因素推断自动驾驶汽车驾驶环境的潜在风险研究工作还很少,从参阅到的文献分析,还几乎没有采用基于“知识图谱+逻辑推理”的方法对自动驾驶潜在风险评估的研究. 本文主要贡献总结如下: 1) 基于本体论初步构建了一个描述自动驾驶场景中实体、属性及实体间交互信息的“城市道路驾驶场景知识图谱(knowledge graph of urban scenarios for autonomous driving, USAD-KG)”用于对自动驾驶场景理解; 2) 构建了用于判断常见视野遮挡场景潜在风险的风险评估知识库; 3) 首次提出了一种根据环境影响因素评估潜在风险概率的贝叶斯网络(Bayesian network, BN)模型,实现对潜在风险概率的评估.

2 方法介绍

基于“知识图谱+逻辑推理+贝叶斯推理”的城市道路自动驾驶场景潜在风险评估方法主要包含潜在风险预判模型(见第2部分)和潜在风险概率评估模型(见第3部分),整体框架如图1所示.

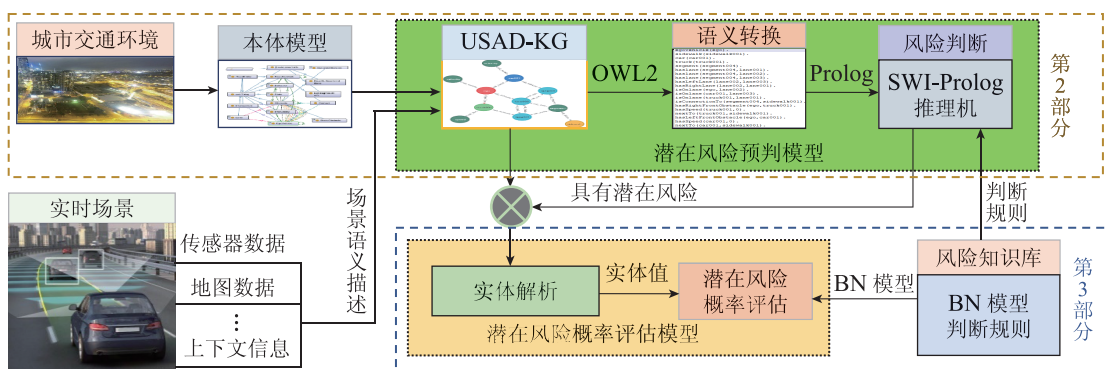


图1 自动驾驶场景潜在风险评估系统框图

Fig. 1 Block diagram of potential risk assessment system

1) 潜在风险预判模型. 首先,根据本体论建立描述有关车辆、行人、道路基础设施、交通环境状态等信息的城市交通环境本体模型;其次,通过语义描述技术将车载传感器采集的原始信号、上下文环境信息等生成语义描述信息,依据所建立的本体模型对驾驶场景进行实例化生成实时USAD-KG;再将USAD-KG

的OWL2(web ontology language 2, OWL2)语言描述语句转换成Prolog描述语句,推送给SWI-Prolog推理机;最后,推理机将实时遮挡场景信息与风险知识库中的风险判断规则进行匹配,实现对遮挡场景是否具有潜在风险的在线逻辑判定.

2) 潜在风险概率评估模型. 视野遮挡潜在风险常

常存在于道路交通场景中, 但具有发生概率低的特点, 所以潜在风险概率评估模型仅对经潜在风险预判模型判断具有潜在风险的场景进行风险概率评估. 模型通过对驾驶场景中的实体数据信息进行解析后, 使用风险知识库中的BN模型对潜在风险进行概率评估.

需要说明的是: 目前, 对图像的语义描述已有大量的研究, 并已经取得了丰富研究成果, 本方法是在假设自动驾驶汽车能够实现对周围环境准确语义描述的基础上展开研究的.

3 潜在风险预测判断

驾驶场景中是否存在潜在风险首先由潜在风险预判模型进行预测判断, 主要包含3个步骤: 构建描述驾驶场景的知识图谱; 对实例场景的描述进行语义转换;

建立风险评估规则并使用推理机按照根据规则对实时场景进行风险预判.

3.1 USAD-KG构建

USAD-KG是建立城市道路驾驶场景的数据模型, 即采取特定形式表示领域知识, 并构建包含概念、属性及概念间关系的本体模型对城市道路交通知识进行语义描述^[17].

3.1.1 驾驶场景本体概念模型

本文基于OWL2语言, 使用Protégé Version 5.5作为工具, 在考虑驾驶场景信息的层次性和关联性的基础上, 建立了一种针对自动驾驶汽车的语义本体概念模型, 其层次结构如图2所示.

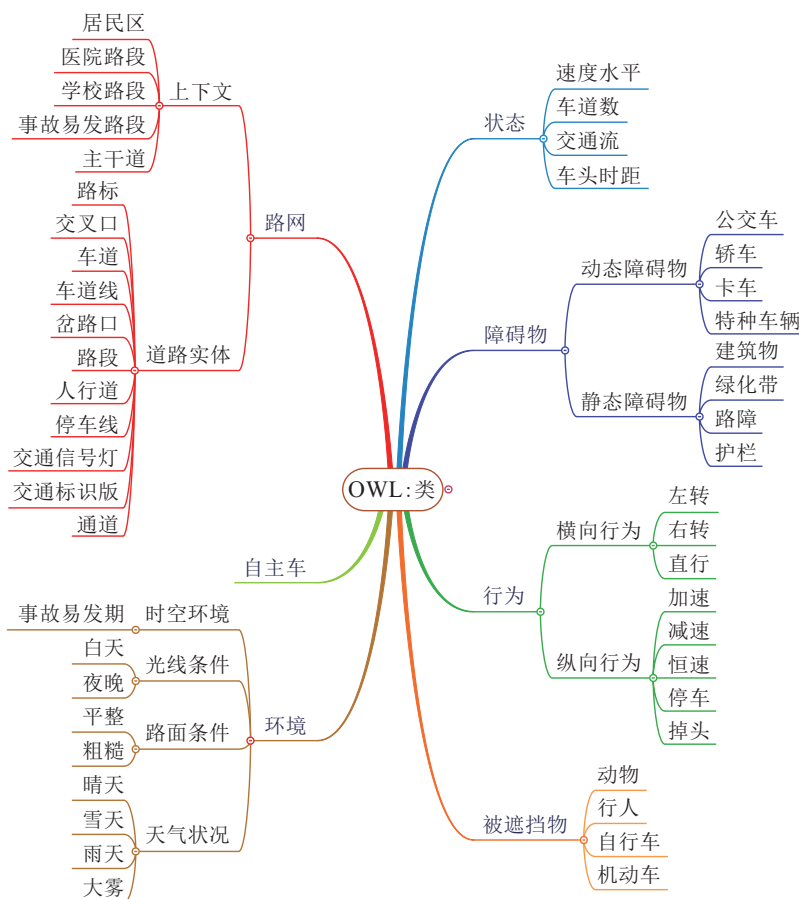


图2 类的层次关系图

Fig. 2 Hierarchy of classes

类: 表示驾驶场景中不同的概念, 本文以自动驾驶汽车的视角归纳整理了如下7类:

- 1) 自主车类(Ego vehicle): 表示自主车.
- 2) 行为类(Behavior): 表示自主车及其周围车辆驾驶行为的集合, 包括横向行为和纵向行为.
- 3) 障碍物类(Obstacle): 表示自动驾驶汽车在行驶过程中遇到的障碍物(包含遮挡物)实体集合.
- 4) 环境类(Environmental): 表示自动驾驶汽车行

驶的宏观环境信息, 如时空特征、天气状况等.

5) 路网信息类(Road network): 表示自动驾驶汽车行驶的城市道路状况.

6) 被遮挡对象类(Occluded object): 表示可能从视野遮挡区域出现的交通参与者类型.

7) 状态类(State): 表示自主车周为环境因素的状态, 用于评估潜在风险.

对象属性: 描述类与类之间的关系.

数据属性: 描述个体和数据值之间的关系.

表1给出了模型的部分对象属性和数据属性.

表 1 所建本体中部分对象属性和数据属性

Table 1 Part of the object attribute and the data attribute

| 部分属性 | 名称 | 定义域 | 值域 |
|------|-------------|-----|--------|
| 对象属性 | hasObstacle | 自主车 | 障碍物 |
| | isOnLane | 车辆 | 车道 |
| | hasState | 障碍物 | 状态 |
| 数据属性 | hasSpeed | 自主车 | 双精度浮点型 |
| | hasDec | 车辆 | 整型 |
| | ValueIs | 状态 | 字符型 |

3.1.2 USAD-KG结构

知识图谱本质上是一张庞大的语义知识网络, 通过语义描述, 把车载传感器从不同数据源中获取到的实体、关系、属性等知识进行融合, 映射到上述构建的本体模型后便可构建USAD-KG, 将建立好的USAD-KG存储于图数据库Neo4j中. 逻辑上, 知识图谱被划分为模式层和数据层, 模式层实质上是完成本体定义的任务, 数据层存储的是具体数据信息^[18]. 一旦实现了对车载传感器信号的语义描述, 即将任何格式的输

入数据转换为三元组, 输出数据就存储在USADKG中, 以直观和分层的方式进行聚合和组织. 图3给出了一个简单描述实例驾驶场景的知识图谱, 并展示了场景中实体交互关系是如何通过本体概念模型来表示的. 图3(a)描述了实例交通场景的场景信息, 图3(b)是把传感器获取的数据映射到模式层后形成的知识图谱.

3.2 语义转换

USAD-KG是基于OWL2本体语言对城市道路交通场景的建模, 自动驾驶汽车对潜在风险推理判断还需要判断规则, 只有事实与规则匹配一致, 才能逻辑推理出潜在风险是否存在. 但是OWL2只是一种描述性的语言, 并不能进行任何推理和计算, 它只有借助于推理机对所描述的内容进行推理, 其描述才有意义. 本文按照语法对应关系, 将基于OWL2语言的描述转换为基于Prolog语言的描述, 然后借助于推理机实现实时的逻辑推理. 语义转化将OWL2语句转化成形如 $P(e)$ 或 $P(e_i, e_j)$ 的Prolog事实语句, 两种语句的对比如表2所示. 在对潜在风险类型进行推断时, 推理机通过加载转换以后的Prolog程序文档, 将事实描述文本与第2.3.1节中建立的潜在风险判断规则进行实时匹配判断.

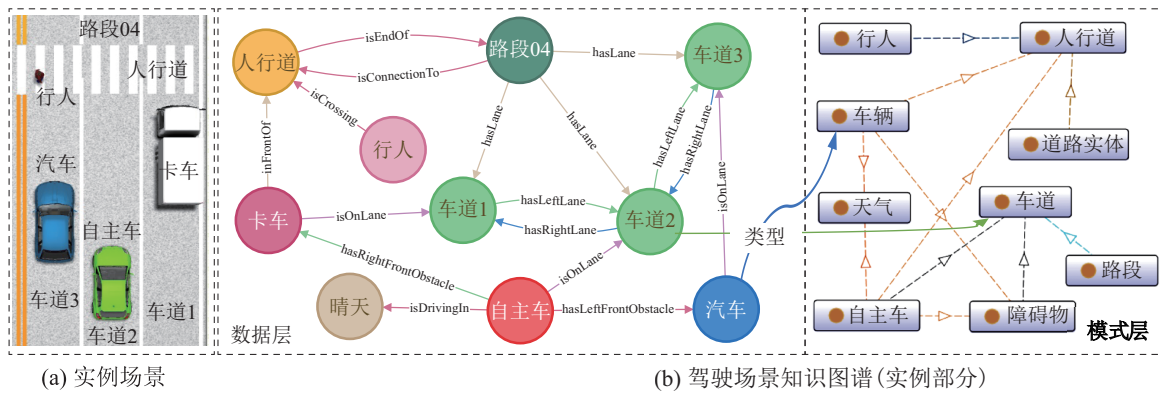


图 3 驾驶场景知识图谱模型

Fig. 3 KG of the instance scenario

表 2 OWL2语句与Prolog语句的对比

Table 2 The comparison of OWL2 statement and Prolog statement

| 内容 | OWL2语句 | Prolog语句 |
|-----------------|---|--|
| Class | Declaration(Class(:EgoVehicle)) | Class (EgoVehicle) |
| Object property | # Object Property: :hasLeftObstacle (hasLeftObstacle) AnnotationAssertion (rdfs: label: hasLeftObstacle“hasLeftObstacle”) ObjectPropertyDomain (:hasLeftObstacle :EgoVehicle) ObjectPropertyRange (:hasLeftObstacle :Obstacle) | hasLeftObstacle (EgoVehicle, Obstacle) |
| | # Data Property: :hasSpeed (hasSpeed) AnnotationAssertion (rdfs:label:hasSpeed“hasSpeed”) DataPropertyDomain (:hasSpeed: EgoVehicle) DataPropertyRange (:hasSpeed xsd:double) | hasSpeed (EgoVehicle, xsd:double) |
| Individual | # Individual: :ego (ego) AnnotationAssertion (rdfs:label :ego“ego”) ClassAssertion (:EgoVehicle :ego) ObjectPropertyAssertion (:hasLeftObstacle :ego :truck025) | EgoVehicle (ego) hasLeftObstacle (ego,truck025) |

3.3 潜在风险预测判断

3.3.1 潜在风险判断规则

在自主车对驾驶场景中视野遮挡潜在风险评估之前, 首先要判断遮挡场景中是否存在潜在风险. 本文结合人类专家经验知识, 对常见的具有潜在风险的“鬼探头”交通场景, 采用Prolog语言编写了潜在风险判断规则, 规则语句中的谓词采用本体模型所建立的词汇. 如表3仅列举了3种视野遮挡场景的潜在风险判断规则.

表 3 具有潜在风险的常见交通场景及风险评估规则

Table 3 Potential risk assessment rule for some scenarios

| 具有潜在风险的场景描述 | 风险评估规则 |
|--------------------------------|--|
| 在人行横道前相邻车道上停止的车辆前方遮挡区域有潜在风险 | hasrisk(ego, risk1): - egoVehicle(Ve), segment(Segm), haslane(Segm,Lane), isOnlane (Ve,Lane), sidewalk(Sd), (hasRightFrontObstacle(Ve,V1); hasLeftFrontObstacle (Ve,V1)), nextTo(V1,Sd), hasSpeed(V1,S), S=<3 |
| 交叉路口处, 在相邻车道排队等候的车辆之间遮挡区域有潜在风险 | hasrisk(ego, risk2): - egoVehicle(Ve), intersection(Inte), segment(Segm), vehicle (Vs) isConnectionTo(Segm, Inte), haslane(Segm,Lane1), isOnlane (Ve, Lane1), (hasLeftLane(Lane1, Lane2); hasRightLane(Lane1, Lane2)), hasVehicleQueue(Lane2,Vs) |
| 绿化带中间豁口遮挡区域有潜在风险 | hasrisk(ego, risk7): - egoVehicle(Ve), segment(Segm), hasLane(Segm, Lane), isOnLane (Ve, Lane), greenBelt(GB), gap(GP), hasGap(GB, GP), isBesideOf(GB, Lane), hasSpeed (ego, Vego), Vego>10, write('There are potential risks in the', tab(1), write(GP), tab(1), write('of'), tab(1), write(GB), nl |

4 潜在风险概率评估

针对第2部分判断具有潜在风险的驾驶场景, 本部分任务是建立模型量化其潜在风险大小, 主要包含两部分任务: 评估模型构建与潜在风险概率评估. 考虑交通参与者的不确定性, 方法采用BN对潜在风险实施推理量化.

4.1 BN的推理

BN是用来表示变量之间概率依赖关系的有向无环图, 它是一种模拟人类推理过程中因果关系的不确定性处理模型. BN推理主要包括预测推理、诊断推理以及预测与诊断相结合的推理. 预测推理是已知一定的原因(父节点), 经推理计算, 求出在这些原因下, 结果(子节点)发生的概率

$$P(Y | X_n, \dots, X_1) = P(Y | p_a(Y)), \quad (1)$$

式中: X, Y 均为自由变量, $p_a(Y)$ 是节点 Y 的父节点集合. 诊断推理正好与预测推理相反, 是由结论来推知原因, 即已知发生了某些结果, 求出造成该结果发生的各种各样的原因的概率

$$P(X | Y) = \frac{P(Y | X)P(X)}{P(Y)}. \quad (2)$$

本文自主车是通过周围环境对潜在风险进行概率评估, 故采用BN的预测推理功能.

3.3.2 潜在风险判断

风险评估规则(库)建立后, 系统根据风险评估规则可以对驾驶场景潜在风险进行在线推理判断. 本文选择SWI-Prolog作为潜在风险推理机, 其推理效率高, 更重要的是, 程序可以方便地被外部程序调用. SWI-Prolog的推理过程是通过模式匹配、回溯等方法的逆向推理, 推理过程如图4所示. 推理机推理输出为二值形式结果: “true”: 表示驾驶场景有潜在风险, 和“error”: 表示规则与事实不匹配, 驾驶场景没有潜在风险.

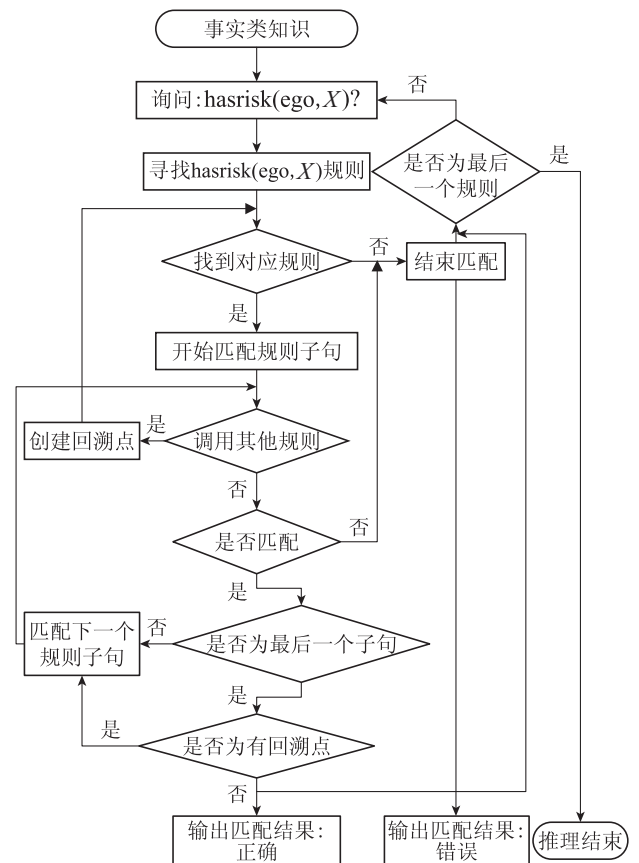


图 4 Prolog推理匹配过程

Fig. 4 Matching process of Prolog reasoning

4.2 潜在风险概率评估模型

潜在风险概率评估的主要流程为: 首先, 当SWI-Prolog推理机对环境匹配得到驾驶场景具有某种潜在风险后, 系统采用Python语言对驾驶场景信息中的实体进行解析, 生成实体信息文件. 其次, 将实体信息文件导入BN中, 应用BN推理功能推理潜在风险概率值.

4.2.1 潜在风险概率评估BN模型

受人类驾驶员常常根据周围环境因素判断其潜在风险启发, 本文根据从知识图谱中解析出的相关环境因素实体信息建立BN, 本文主要通过查阅文献和咨询专家来选取影响潜在风险的环境因素.

文献[19]通过以往视频资料观测在密歇根州立大学附近无信号控制的路段, 超过80%的行人会选择人行横道. 文献[20]对行人在无信号指示灯过街横道处违章过街行为的研究中, 得到的1275组样本数据显示影响行人决定是否“违章过街”的因素主要有道路中央分隔带、单向车道数、车速、交通量及过街设施的配置, 各因素对行人过街行为的影响在文中也进行了详细统计. 结合上述文献结论, 本文通过以下环境因素的状态预测潜在风险:

- 1) 可行驶通道(c_r): 指交互区域是否为交通参与者按照交通规则可行驶的通道;
- 2) 风险智能体流量(ω_0): 指交通参与者(简称风险智能体)在遮挡区域周围的流量水平;
- 3) 穿越车道数(n_1): 指交通参与者从遮挡区域出现后可能穿越的单向车道数;
- 4) 遮挡物速度(v_o): 指遮挡物朝着遮挡区域方向移动的速度水平, 静态遮挡物 $v_o = 0$;
- 5) 隔离带(d_i): 指交通参与者穿越的通道上是否有隔离阻挡物, 如道路中间或路边的护栏等;
- 6) 车头时距(t_h): 指自主车与同车道前方车辆的车头时距;
- 7) 时空上下文(s_t): 除上述因素外, 结合人类驾驶时推断经验, 模型还考虑了在上下班高峰期或位于学校、住宅区等行人易出现的上下文因素.

根据上述7个环境影响因素, 建立BN模型, 如图5所示, 本文借助GeNIe软件来帮助构建初步的BN.

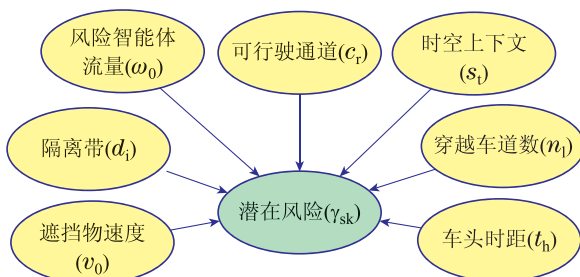


图5 BN模型结构

Fig. 5 BN model structure

图5中各节点包含的状态及含义如表4所示, 相关应用阐释见第3.2.2节.

表4 BN节点变量包含的状态及其含义

Table 4 The meaning and states of BN nodes

| 节点 | 状态 | 含义 | 取值 |
|---------------|------------|------------------------|-----------|
| c_r | 是 | 是 | 1 |
| | 否 | 否 | 0 |
| ω_0 | ω_0 | $\omega = 0$ | 0 |
| | ω_1 | $0 < \omega/60 \leq 1$ | 1 |
| | ω_2 | $1 < \omega/60 \leq 2$ | 2 |
| | ω_3 | $2 < \omega/60 \leq 3$ | 3 |
| | ω_4 | $3 < \omega/60 \leq 4$ | 4 |
| | ω_n | $\omega/60 > 4$ | $+\infty$ |
| n_1 | 1 | 1条车道 | 1 |
| | 2 | 2条车道 | 2 |
| | 3 | 3条车道 | 3 |
| | ≥ 4 | ≥ 4 条车道 | 4 |
| v_o | 静止 | $v_o = 0$ m/s | 0 |
| | 低速 | $0 < v_o \leq 3$ m/s | 3 |
| | 中速 | $3 < v_o \leq 7$ m/s | 7 |
| s_t | 高速 | $v_o > 7$ m/s | 9 |
| | 是 | 容易出现行人 | 1 |
| d_i | 否 | 一般情况 | 0 |
| | 是 | 通道设有阻碍通行的障碍物 | 1 |
| t_h | 否 | 通道没有阻碍通行的障碍物 | 0 |
| | 是 | 车头时距 ≤ 2.7 s/Veh | 1 |
| γ_{sk} | 否 | 车头时距 > 2.7 s/Veh | 0 |
| | 是 | 风险 | 1 |
| | 否 | 安全 | 0 |

4.2.2 确定条件概率

BN推理必须先要确定条件概率(conditional probability, CP). 行人出入视野遮挡区域的行为是随机性的, 理论与现实研究表明, 泊松分布模型能够很好地预估随机事件发生概率, 设行人到达遮挡区域的数量服从泊松分布

$$P(N(t) = n) = \frac{(\lambda t)^n e^{-\lambda t}}{n!}, \quad (3)$$

式中: P 表示概率, N 为某种函数关系, t 为时间, n 为事件发生的数量, λ 为事件的频率. 设每分钟内行人平均到达遮挡区域的人数为 ω , 则行人随机横穿道路概率

$$P(\gamma_{sk} = 1) = 1 - e^{-K_p \cdot (1 - e^{-\omega/60})}, \quad (4)$$

式中: $\gamma_{sk} = 1$ 表示“行人横穿道路”事件的概率; $1 - e^{-\omega/60}$ 表示单位时间内有行人抵达遮挡区域的概率; $e^{-\omega/60} = P(N(t = 1 \text{ s}) = 0)$ 为无人抵达遮挡区域的概率; K_p 为环境影响系数, 表示所选取的环境因素对“行人从遮挡区域窜出”事件的影响, 其关系为

$$K_{\rho} = \frac{k_c^{(1-c_r)} \times k_d^{(d_i)} \times k_t^{(t_h)}}{k_v^{(v_o)} \times n_1} e^{s_t}, \quad (5)$$

式中: k_c 表示“交通参与者违章穿越道路概率系数”,服从正态分布; k_d 表示“隔离带影响系数”; k_t 表示“车头时距影响系数”; k_v 表示“障碍物速度影响系数”. 参照文献[19–20]试验统计数据, 本文各系数取值为 $k_c \sim N(0.4, 0.02)$, $k_d = 0.46$, $k_v = 1.45$, $k_t = 0.05$.

BN适用在节点的性质是属于离散型的情况下, 而上述模型中, 动态遮挡物的速度“ v_o ”和交通参与者的流量“ ω_o ”的值是连续性的, 不适合BN推理. 故本文对这两个因素的状态分别按阶段水平取值, 详见表4: 对于“ v_o ”, 当 $v_o = 0$ m/s时, 为“static”状态, 值取0; 当 $0 < v_o \leq 3$ m/s时, 为“low”状态, 值取3; 当 $3 < v_o \leq 7$ m/s时, 为“medi”状态, 值取7; 当 $v_o > 7$ m/s时, 为“high”状态, 值取9. 由于流量大小随机性很强, 本研究采用蒙特卡洛模拟方法, 在确定了其他状态值下, 对不同流量水平分别抽样若干次, 按照式(4)求得潜在风险近似解.

以图6(a)所示的某无信号控制路段 $s_t = 1$, $c_r = 1$, $d_i = 0$, $v_o = 0$, $n_1 = 3$, $t_h = 0$ 为例, 对不同流量 ω_o 分别随机抽样1000次, 计算各流量水平下的潜在风险概率平均值“ p_r ”为各流量水平下的潜在风险概率, 即 $P(\gamma_{sk} = 1) = p_r$, 其模拟结果如图6(b)所示. 因在流量 ω_4 下的风险概率与无穷大流量 ω_n 下的风险概率值很接近, 所以本文用 ω_4 状态下的风险概率统一表示 ω_4 及更高状态下的风险概率. 同理, 可以计算出 n_1 , c_r , d_i , v_o 和 t_h 在各种水平联合分布下的潜在风险概率, 其结果构成了BN的条件概率CP. 确定了条件概率后, 根据传感器获取的驾驶场景中各实体状态值对潜在风险的预测推理结果如图6(c)所示.

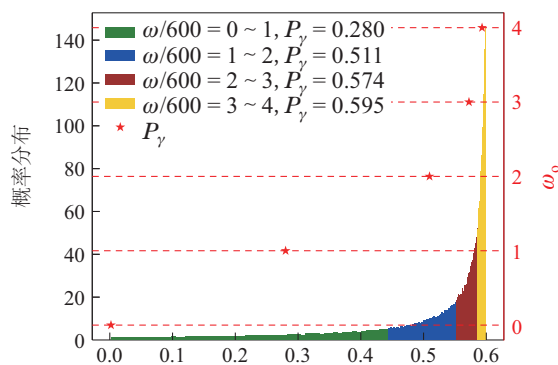
5 实验验证

为了证明所提方法的有效性, 选取了两种真实的驾驶场景对方法进行了实验验证: 在场景1中, 对实车驾驶场景进行了潜在风险评估, 并将评估结果应用到本研究前期工作关于车辆行驶决策的模型^[21]中, 通过仿真实验生成了车辆的速度曲线, 并与实际场景中人类驾驶车辆的速度曲线进行对比分析; 在场景2中, 验证利用提出的方法能够预测一些人类驾驶因疏忽或未及时能预测出的潜在风险.

场景1 在西安市兴庆路选取了大约长100 m且具有一个变道口的繁华路段进行了现场测试, 如图7(a)所示. 为了与人类驾驶效果比较, 实验车辆由一名具有多年驾驶经验的驾驶员在驾驶操作, 车载GPS采集了车辆的轨迹、行驶速度等数据, 数据采集的频率为10 Hz, 同时CCD摄像机对驾驶场景进行了全程录制. 本文对车辆在该路段行驶的11 s视频进行分析.

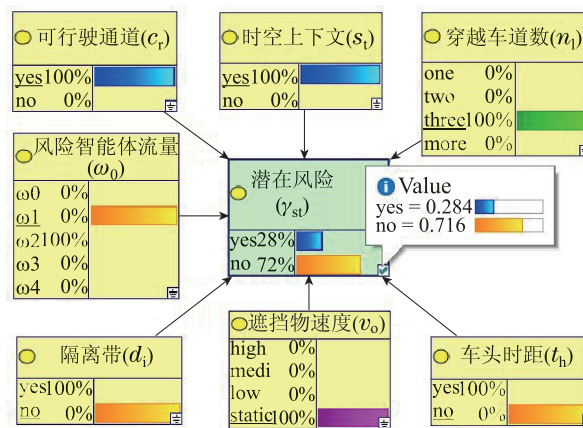


(a) 驾驶场景图



$P(\gamma_{sk}=1) (s_t = 1, c_r = 1, d_i = 0, v_o = 0, n_1 = 3, t_h = 0)$

(b) 条件概率分布模拟图



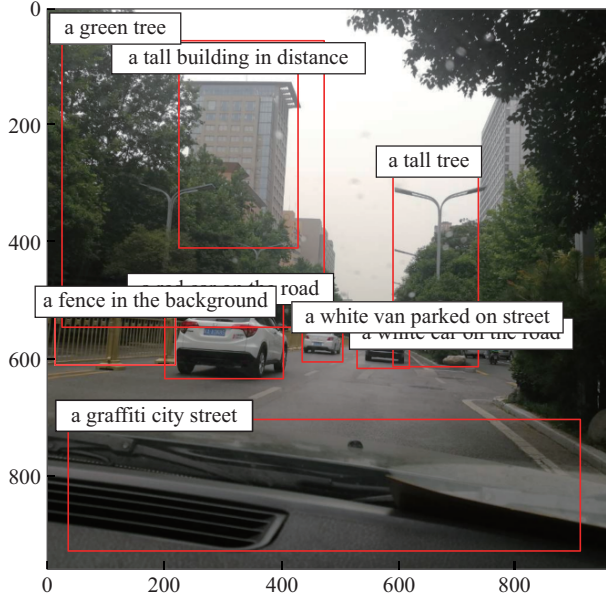
(c) 潜在风险预测推理效果图

图6 视野遮挡潜在风险评估示例

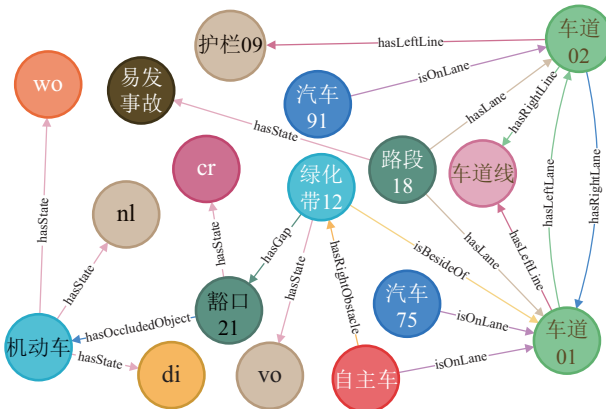
Fig. 6 Example of potential risk assessment under vision occlusion



(a) 现场测试路段



(b) 视频第3秒实时场景



(c) 实时场景实体关系知识图谱

图7 实时场景知识图谱

Fig. 7 Real-time scene knowledge graph

首先,从11 s视频中每隔一秒截取一幅场景图像,进行分析判断,如图7(b)为第3 s时截取的场景静态图像.根据本文建立的本体框架,将传感器采集的场景原始数据通过语义描述后生成实例知识图谱,存储于图数据库Neo4j,如图7(c)所示.其次,为了能够逻辑推理实例场景是否具有潜在风险,将场景的owl语句描述转换为Prolog语句描述,存储为.pl文件并推送给SWI-Prolog推理机.转换后的Prolog语句描述为:“EgoVehicle(ego). Car(car075). Car(car091). Segment(segment018). Lane(lane001). OccludedObject(pedestrians018). Divider(guardrail009). GreenBelt(greenbelt012). Gap(gap021). isOnLane(ego, lane001)…”最后,根据场景描述文本,SWI-Prolog推理机在风险知识库中寻找与事实类关系相匹配的风险评估规则,进行实时匹配,匹配过程如图8所示.

经匹配,上述事实最终与表3中的规则hasrisk(ego,

risk7): 匹配成功,其输出结果输出为“true”,即表明,绿化带豁口处遮挡区域存有潜在风险.图中输出结果信息中的“**There are potential risks in the gap021 of greenbelt012**”是在规则中设置的提示信息,规则与事实一旦匹配成功,该提示信息便可输出,规则中也可不设置提示信息.经SWI-Prolog推理,第3 s实时场景中存在潜在风险,则对图7(b)驾驶场景信息中的实体信息进行解析,解析结果为: $s_t = 1, t_h = 0, n_1 = 2, c_r = 1, d_i = 1, v_o = 0$.传感器检测到周围机动车或非机动车流量取值在 $1 < \omega/60 \leq 2$,即 $w_0 = 2$.将解析的实体数据文件导入已建的BN中,对各选取时刻的驾驶场景潜在风险值推理得到:第3 s时: $P(\gamma_{sk} = 1) = 0.38$,如图9(a)所示;同样的方法,推得在第2 s时: $P(\gamma_{sk} = 1) = 0.21$,其余时刻判断为无潜在风险.

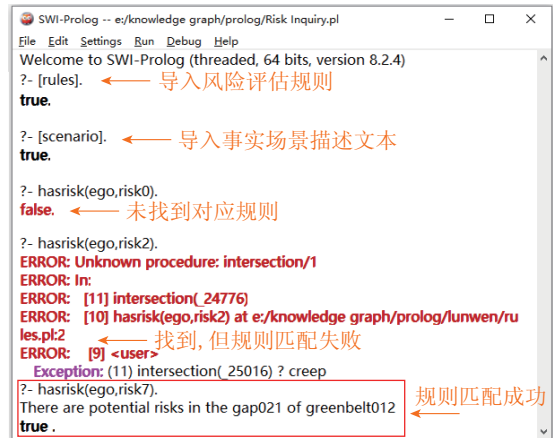
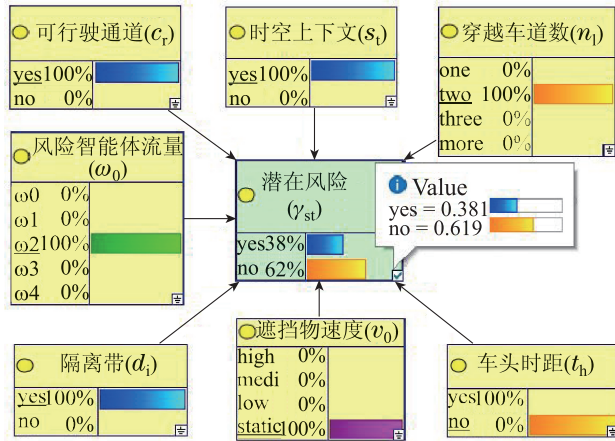





图8 SWI-Prolog推理机对潜在风险实时推理

Fig. 8 Potential risks reasoning in SWI-Prolog


借助本研究的前期工作^[21],将评估的潜在风险结果应用到所建立的运动规划模型中对自动驾驶汽车的运动进行仿真,如图9(b)所示,上层图和中间图分别为第3.2 s、第8.8 s时的仿真效果图,底层图为预测的潜在风险值曲线以及自动驾驶汽车的实时速度曲线图.仿真结果显示,自动驾驶汽车在接近绿化带之间的变道口时,由于采用本文提出的方法,预测到前方存在潜在风险,为了确保安全,车辆采取了减速操作.将自动驾驶汽车速度曲线与实验人员驾驶的汽车速度曲线进行对比,如图9(c)所示,图中紫红色曲线为人类驾驶汽车的速度曲线.对比发现,人类驾驶员在驾驶操作中意识到道路边绿化带变道口处存在潜在风险,为了安全在第2 s过后也采取了制动操作,如在第3 s时,车辆速度明显在下降.对比发现两条速度曲线特征很接近,说明采用本文提出的方法对视野遮挡区域潜在风险的判断,能够得到与人类驾驶员判断的相似效果.



(a) 第 3 s 时刻的潜在风险概率推理



(b) 动态仿真

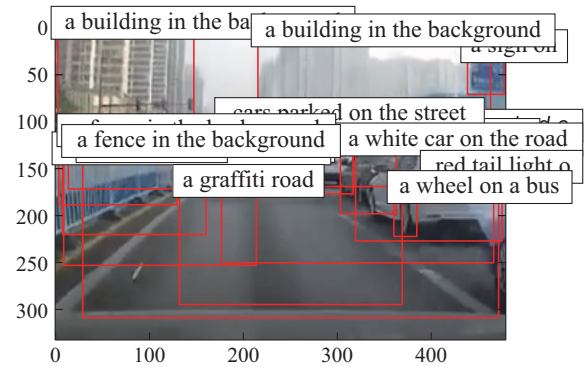


(c) 自主车速度曲线与潜在风险概率值

图 9 场景 1 潜在风险评估结果及其应用效果对比

Fig. 9 Potential risk assessment result and comparison of application effects of the result in Scenario 1

场景 2 场景 2 是取自现实上下班交通中的一次“鬼探头”事故, 由于人类驾驶员未能及时判断周围的潜在风险导致最终发生了交通碰撞事故, 如图 10(a)–(d) 所示. 面对此场景, 自动驾驶汽车采用本文提出的方法, 可以根据风险知识库中的潜在风险判断规则“hasrisk (ego, risk2):”判断出场景存在潜在风险, 再通过潜在风险概率评估模型推理风险的概率大小.




(a) 第 7 s 场景



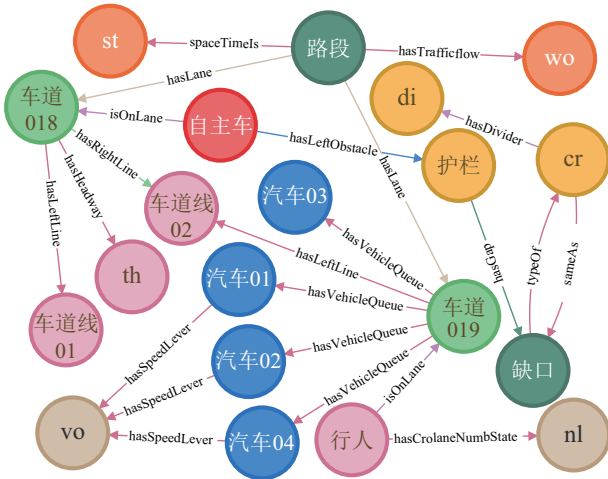
(b) 第 9 s 场景



(c) 第 10 s 场景



(d) 第 13 s 场景



(e) 场景实体关系图谱

```

SWI-Prolog -- e:/knowledge graph/prolog/Risk Inquiry.pl
File Edit Settings Run Debug Help
Welcome to SWI-Prolog (threaded, 64 bits, version 8.2.4)

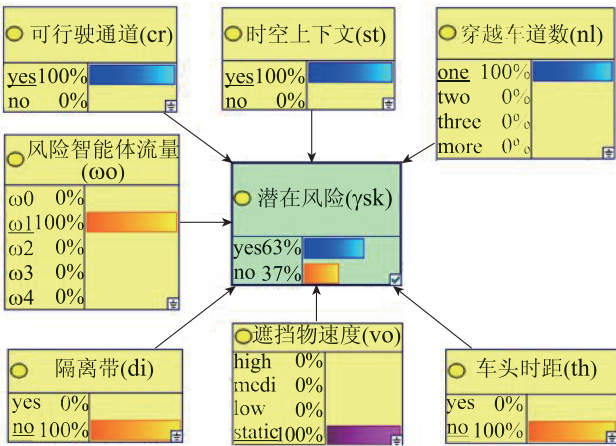
?- [rules].
true.

?- [scenario2].
true.

?- hasrisk(ego,risk).
false.

?- hasrisk(ego,risk1).
ERROR: Unknown procedure: sideWalk/1
ERROR: In:
ERROR: [11] sideWalk(_21160)
ERROR: [10] hasrisk(ego,risk1) at e:/knowledge graph/prolog/rules.pl:1
ERROR: [9] <user>
Exception: (11) sideWalk(_21400) ? creep
?- hasrisk(ego,risk2).
There are potential risks in the lane019
true
  
```

(f) 潜在风险判断



(g) 第9 s时的潜在风险概率评估

图 10 场景2 潜在风险评估

Fig. 10 Potential risk assessment in Scenario 2

本文从视频中截取的第7 s、第9 s场景进行分析。在第7 s时假设车辆已经能够根据车载传感器(或传感器组)识别周围交通参与者,则根据第2部分建立的本体(模式层)生成实例知识图谱,如图10(e)所示;其次,通过SWI-Prolog推理机根据“hasrisk(ego, risk2)”: 风险规则推理输出结果为“true”,如图10(f)所示;最后,采用建立的BN风险概率评估模型对不同时刻的潜在

风险评估。第7 s时对节点的解析值为: $s_t=1, t_h=0, n_l=1, c_r=0, d_i=1, v_o=3, w_o=1$, 推理得到 $P(\gamma_{sk}=1)=0.06$, 风险相对较低;但第9 s时,车辆识别到道路中央的隔离护栏有一个允许非机动车辆通过的缺口,对节点的解析值为: $s_t=1, t_h=0, n_l=1, c_r=1, d_i=0, v_o=0, w_o=1$, 推理得 $P(\gamma_{sk}=1)=0.63$, 如图10(g)所示。通过上述分析,自动驾驶汽车将会在第9 s时根据周围环境因素预测出较高的潜在风险,弥补了人类未及时推理出潜在风险的过失。

通过上述实验验证,本文提出的自动驾驶汽车风险评估模型能够根据周围的环境因素对潜在风险进行判断和概率评估,其结果可为自动驾驶系统或辅助驾驶系统的行为决策提供有效依据。然而,在实际道路交通系统网络中,不仅相关因素繁多,而且,有很多因素的状态概率值是无法得到的,因此本文在推理方法中,结合了已有的研究文献,引入了大量的近似概率值,采用了近似推理。

6 结束语

面向自动驾驶系统传感器视野遮挡潜在风险场景,提出了一种潜在风险评估方法,建立的评估模型能够以概率的方式对自动驾驶汽车视野遮挡区域的潜在风险进行评估。方法基于本体论建立了“城市道路驾驶场景知识图谱”,可以有效地解决在多源异构数据中挖掘交通环境因素和潜在风险的关联性。潜在风险判断规则中代码的编写与潜在风险推理的相关详细信息将人类经验知识转移到人工智能中,从而达到更高的智能水平。然而,影响视野遮挡区域的潜在风险的环境因素还有待进一步深入挖掘,这也为研究后续工作提供了契机。

作为未来的工作: 1) 计划进一步扩展USAD-KG的本体模型,丰富实体类别,全面覆盖交通实体; 2) 基于现实交通规则的描述,补充和完善风险判断规则; 3) 探索更多的影响潜在风险的因素,继续解决风险评估中的相关问题,以适应更多的潜在危险驾驶场景。

参考文献:

- [1] WANG J, HUANG H, LI Y, et al. Driving risk assessment based on naturalistic driving study and driver attitude questionnaire analysis. *Accident Analysis & Prevention*, 2020, 145: 105680.
- [2] ZHANG Jiaxu, ZHOU Shiyong, SHI Zhengtang, et al. Path planning and tracking control for corner overtaking of driverless vehicle using sliding mode technique with conditional integrators. *Control Theory & Applications*, 2021, 38(2): 197 – 205. (张家旭, 周时莹, 施正堂, 等. 采用滑模条件积分的无人驾驶汽车弯道超车路径规划与跟踪控制. *控制理论与应用*, 2021, 38(2): 197 – 205.)
- [3] YU M Y, VASUDEVAN R, JOHNSON R M. Occlusion-aware risk assessment for autonomous driving in urban environments. *IEEE Robotics and Automation Letters*, 2019, 4(2): 2235 – 2241.
- [4] SCHRATTER M, BOUTON M, KOCHENDERFER M J, et al. Pedestrian collision avoidance system for scenarios with occlusions.

- The 30th IEEE Intelligent Vehicles Symposium*. Paris, France: IEEE, 2019: 1054 – 1060.
- [5] LEFEVRE S, VASQUEZ D, LAUGIER C. A survey on motion prediction and risk assessment for intelligent vehicles. *Robomech Journal*, 2014, 1(1): 1 – 14.
- [6] LI G, YANG Y, ZHANG T, et al. Risk assessment based collision avoidance decision-making for autonomous vehicles in multi-scenarios. *Transportation Research Part C: Emerging Technologies*, 2021, 122: 102820.
- [7] BRECHTEL S, GINDELE T, DILLMANN R. Probabilistic decision-making under uncertainty for autonomous driving using continuous POMDPs. *The 17th International IEEE Conference on Intelligent Transportation Systems*. Qingdao, China: IEEE, 2014: 392 – 399.
- [8] YU M Y, VASUDEVAN R, JOHNSON R M. Risk assessment and planning with bidirectional reachability for autonomous driving. *International Conference on Robotics and Automation*. Paris, France: IEEE, 2020: 5363 – 5369.
- [9] SHANG Weichao. *Research on identification and risk assessment of potential dangerous scenes on urban roads*. Xi'an: Xi'an University of Technology, 2021.
(商伟超. 城市道路潜在危险交通场景识别与风险评估研究. 西安: 西安理工大学, 2021.)
- [10] ONDRUSKA P, POSNER I. Deep tracking: Seeing beyond seeing using recurrent neural networks. *ArXiv Preprint*, 2016: arXiv:1602.00991.
- [11] DEQUAIRE J, ONDRUSKA P, RAO D, et al. Deep tracking in the wild: End-to-end tracking using recurrent neural networks. *The International Journal of Robotics Research*, 2018, 37(4/5): 492 – 512.
- [12] THORNTON S M, LEWIS F E, ZHANG V, et al. Value sensitive design for autonomous vehicle motion planning. *Intelligent Vehicles Symposium*. Changshu, China: IEEE, 2018: 1157 – 1162.
- [13] KATRAKAZAS C, QUDDUS M, CHEN W H. A new integrated collision risk assessment methodology for autonomous vehicles. *Accident Analysis and Prevention*, 2019, 127: 61 – 79.
- [14] HUBMANN C, QUETSCHLICH N, SCHULZ J, et al. A POMDP maneuver planner for occlusions in urban scenarios. *Intelligent Vehicles Symposium*. Paris, France: IEEE, 2019: 2172 – 2179.
- [15] ELAHI M F, LUO X, TIAN R. A framework for modeling knowledge graphs via processing natural descriptions of vehicle-pedestrian interactions. *The 22nd HCI International Conference*. Copenhagen, Denmark: 2020, 40 – 50.
- [16] HALILAJ L, DINDORKAR I, LUTTIN J, et al. A knowledge graph-based approach for situation comprehension in driving scenarios. *The 18th Extended Semantic Web Conference*. Electr Network: 2021, 12731: 699 – 716.
- [17] AYDIN S, AYDIA M N. Ontology-based data acquisition model development for agricultural open data platforms and implementation of OWL2MVC tool. *Computers and Electronics in Agriculture*, 2020, 175: 105589.
- [18] JI S, PAN S, CAMBRIA E, et al. A survey on knowledge graphs: Representation, acquisition, and applications. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(2): 494 – 514.
- [19] AKIN V P S D. Pedestrian behaviors at and perceptions towards various pedestrian facilities: An examination based on observation and survey data. *Transportation Research Part F*, 2003, 6(4): 249 – 274.
- [20] LIU Lijuan. *Reserch on pedestrian crossing behavior at mid-block street crosswalk*. Changsha: Changsha University of Science & Technology, 2014.
(刘丽娟. 城市道路路段行人过街行为研究. 长沙: 长沙理工大学, 2014.)
- [21] WANG D, FU W, SONG Q, et al. Potential risk assessment for safe driving of autonomous vehicles under occluded vision. *Scientific Reports*, 2022, 12(1): 1 – 14.

作者简介:

王登贵 副教授, 博士研究生, 目前研究方向为智能汽车无人驾驶/辅助驾驶技术, E-mail: guidengwang1981@126.com;

傅卫平 教授, 博士生导师, 目前研究方向为机电系统动力学及其控制、智能车辆控制理论与技术, E-mail: weipingf@xaut.edu.cn;

周劲草 讲师, 博士, 目前研究方向为汽车主动安全与计算机视觉技术, E-mail: jzhou324@xaut.edu.cn;

高志强 讲师, 硕士生导师, 博士, 目前研究方向为机械系统动态性能分析与优化, E-mail: gaozhiqiangjk@163.com;

宋清源 博士研究生, 目前研究方向为自动驾驶汽车认知与决策技术, E-mail: songqingyuanjj@126.com.