

KG 存储协同 CoT 推理: 构建车辆风险分析智能体*

易智君¹, 韦邦彦², 徐永高¹, 武小云¹, 朱依婷², 何兆成²

1. 广东省道路运输事务中心, 广东 广州 510199

2. 广东省智能交通系统重点实验室 / 中山大学智能工程学院, 广东 深圳 518107

摘要: 文中提出了一种基于知识图谱与思维链(CoT)引导的大语言模型的车辆风险分析智能体框架。首先, 面向重点车辆的安全监管, 将分散的风险驾驶行为、交通事故与路网数据等信息建模为统一的风险知识图谱语义网络。然后, 设计了基于提示词工程的分级推理 CoT 架构, 引导大语言模型实现理解问题、查询数据、确认结果和修正查询的可溯源推理过程, 提升问答的准确性与鲁棒性。实验证明, 车辆风险分析智能体能够有效支持自然语言交互下的风险分析与关联挖掘, 在多种复杂查询任务中表现良好, 并能结合子图分析为交通管理提供高效、智能和可解释的决策分析工具。

关键词: 车辆; 风险分析; 知识图谱; 大语言模型; 思维链; 智能体

中图分类号: U491 **文献标志码:** A **文章编号:** 2097-0137(2026)01-0085-08

KG storage and CoT reasoning: Construct the intelligent agent for vehicle risk analysis

YI Zhijun¹, WEI Bangyan², XU Yonggao¹, WU Xiaoyun¹, ZHU Yiting², HE Zhaocheng²

1. Guangdong Road Transport Affairs Center, Guangzhou 510199, China

2. Guangdong Provincial Key Laboratory of Intelligent Transportation System / School of Intelligent Systems Engineering, Sun Yat-sen University, Shenzhen 518107, China

Abstract: This paper proposes a vehicle risk analysis intelligent agent framework integrating knowledge graph technology and large language model (LLM) guided by chain-of-thought (CoT). We construct a risk knowledge graph tailored for critical vehicle safety supervision to unify fragmented data including risky driving behaviors, traffic accidents, and road network information into a cohesive semantic network. And a hierarchical CoT reasoning architecture grounded in prompt engineering is designed to steer the LLM through a traceable inference pipeline comprising query comprehension, data retrieval, result validation and query refinement, thereby enhancing the accuracy and robustness of question-answering systems. Experimental validation confirms that the proposed intelligent agent of vehicle risk analysis effectively facilitates natural language-driven risk assessment and association mining across diverse complex query scenarios, delivering an efficient, intelligent, and interpretable decision-support tool for traffic management with demonstrable superiority in operational efficacy and analytical transparency.

Key words: vehicle; risk analysis; knowledge graph; LLM; chain-of-thought; intelligent agent

* 收稿日期: 2025-09-30

录用日期: 2025-10-31

网络首发日期: 2026-01-02

基金项目: 国家重点研发计划(2023YFB4301900)

作者简介: 易智君(1976年生), 女; 研究方向: 交通运输; E-mail: 915184458@qq.com

通信作者: 何兆成(1976年生), 男; 研究方向: 智能交通系统; E-mail: hezhch@mail.sysu.edu.cn

全文阅读



ZR20250213

“两客一危一重”重点车辆(以下简称重点车辆)具有载客量大、车体庞重或运输高危物品的特点,一旦发生事故,极易造成群死群伤、重大财产损失,甚至引发环境污染灾难。因此,加强对重点车辆的风险管控具有重要的社会意义(柏峰, 2022)。交通管理部门通过在重点车辆上安装摄像头、定位设备等,通过图像识别和机器学习等及时发现驾驶员分心驾驶、超速等高风险行为(Bouhsissin et al., 2024; Jiang et al., 2022)。此类交通数据同时记录了车辆运行轨迹和车辆的驾驶行为,具有强烈的时空关联性、多源异构性以及复杂的语义结构(刘奕含等, 2024),表现为时间上的连续演化与空间上的紧密耦合,更多的监管数据还可能来源于道路监控系统和管理业务平台等渠道,格式上除结构化数据库,还包括半结构化日志以及非结构化文本,呈现出高度的异构性。

传统的交通数据分析方法面向独立对象进行单一维度的统计分析,依赖人工预设规则或静态模型,缺乏对跨实体、跨层级复杂关系的分析能力,在应对综合性查询时,往往数据关联繁琐、推理链条断裂或计算响应迟缓,导致难以有效整合与挖掘其深层价值(Qi et al., 2024)。因此,亟需一种能够融合多源信息、支持语义理解与逻辑推理的数据管理方法,以实现从数据驱动向知识驱动的跃迁。

知识图谱(KG, knowledge graph)凭借在实体关联建模方面的突出能力,已在知识表示、挖掘与推理等多个领域展现出广阔的应用前景。它以结构化的图形式刻画现实世界中的客观事实,将信息表达为“头实体—关系—尾实体”的三元组基本单元,实现对复杂语义关系的精准描述。通过融合不同来源、格式各异的多源异构数据,KG能够构建出反映真实交通场景的网络化结构,并借助图计算、路径推理与模式匹配等,深入挖掘节点间的潜在关联,揭示传统方法难以捕捉的空间与逻辑相关性。

相较于传统的数据分析技术路径,KG具备更强的可解释性优势。其构建过程、推理路径及关联规则均可通过可视化手段直观呈现,使分析结果更具透明度和可信度(江旭晖等, 2023)。随着智慧交通系统对数据语义理解与智能决策支持需求的不断提升,KG在该领域的作用日益凸显。围绕交通领域KG的构建方法、表示学习机制、推理技术及其在道路风险预警(王占中等, 2025)、道路流量预测(李劲业等, 2024; Zeng et al., 2023)、旅行轨迹跟踪(Chen et al., 2022)、车辆排放调查(Zhao, 2023)等场

景的探索,已成为应用研究的重点方向。Liu et al. (2022)基于427份铁路事故报告,通过命名实体识别技术,实现了对危险、故障与事故之间潜在关系的可视化呈现及定量描述,为铁路风险防范提供了辅助支持。Yu et al. (2024)基于碎片化事故报告的结构化整合,构建了包含事故、人员、车辆、环境等多层级KG语义网络,有效实现和支撑了交通事故画像的关联推理、智能决策与交通数据挖掘等。Zhu et al. (2023)提出融合KG、卷积图神经网络与双向长短期记忆网络的交通事故预测方法,结合时序模型实现了对事故风险等级的动态预测。

但是,KG的知识覆盖范围受限于数据源的完整性与更新频率,且高质量的KG构建依赖对实体、关系和本体结构等的正确建模。此外,针对图数据库的查询操作通常需要掌握特定的查询语言,这对非技术背景的相关部门管理人员构成了较高的使用门槛,限制了其在实际场景中的广泛应用。在此背景下,大型语言模型(LLM)凭借其强大的自然语言理解与生成能力,为KG的构建与应用提供了新的技术路径。通过LLM能够从非结构化文本中自动抽取实体与关系,辅助完成知识融合与图谱补全,并可通过自然语言接口实现对KG的免编程查询与推理(Gijre et al., 2024)。同时,LLM作为黑箱模型,在开放域问答中存在幻觉问答,影响数据分析结果的可靠性(Chen et al., 2024)。而KG的事实数据作为外部知识源,对LLM的推理过程进行约束和校验,可以有效抑制其幻觉输出,尤其适合精确问答分析任务(Li et al., 2025)。

因此,LLM与KG在知识处理能力上具有天然的互补性,二者融合被视为提升智能系统可信性与智能化水平的重要方向。Pan et al. (2024)系统性地提出了LLM与KG结合的3种技术路径,如图1所示。具体如下:(1)将KG中的结构化知识作为外部知识源输入至LLM,作为推理依据以增强其回答的准确性与可解释性。(2)利用LLM强大的语义解析能力优化KG的构建流程,包括实体识别、关系抽取与知识补全等环节。(3)在统一框架下协同融合LLM与KG,共同参与知识表示与复杂推理任务,实现双向增强。

Hogan et al. (2021)利用LLM从非结构化的交通事故报告中自动提取结构化信息用于KG构建,并进一步借助LLM实现自然语言到Cypher查询语句的转换。Hou et al. (2025)通过LLM从事故记录中提取知识并构建KG,KG除了辅助事故分析还可



图 1 LLM 与 KG 结合的 3 种技术路径

Fig. 1 Three technical pathways of LLM and KG integration

与 LLM 协同用于自动驾驶中的事故模拟场景生成。针对交通领域车辆多源异构时空数据分析难题, 本文通过协同融合 KG 的可解释性关联分析能力与 LLM 的自然语言推理交互功能, 打造面向重点车辆安全监管、具有车辆风险数据分析技术路径的交通智能体。智能体将支持安全监管数据关联分析、车辆安全监管报告生成等应用, 能够帮助管理者快速定位重点车辆风险源头, 降低风险识别的时间周期, 提升安全监管的效率。

1 可计算重点车辆风险的知识图谱

记录和监管风险驾驶行为的目的是降低交通事故的发生率, 因此本文从交通部门获取风险驾驶行为记录数据同时段的结构化交通事故记录数据。来自多源设备的风险驾驶行为数据与交通事故记录数据共同构成了车辆风险分析的知识图谱基础, 其重要数据字段如表 1~2 所示。

风险驾驶行为是事故的潜在前兆, 而交通事故则是风险行为可能引发的严重后果。风险驾驶行为与交通事故的时间字段形成了时间序列上的连续链条。同时, 经纬度字段记录事件的空间位置, 经纬度数据与高速公路可计算路网进行匹配, 识别出事故高发的热点区域。本文还通过既有地理空间算法有效识别风险事件所在道路桩号 (Zeng et al., 2012) 并补充至风险驾驶行为记录数据字段。

基于多源数据的特征分析, 构建面向重点车辆安全监管的风险知识图谱 (RKG, risk knowledge

表 1 风险驾驶行为记录数据字段
Table 1 Fields of risky driving behaviors

字段	说明
车辆 ID	车辆车牌加密后唯一值
业户 ID	车辆所属公司名称加密后唯一值
地市	公司所在城市
区县	公司所在区/县
经营范围	重型货车、危险货运、客运车辆
发生时间	风险驾驶行为发生、创建、处置的时间, 格式: 年-月-日 小时: 分钟: 秒
创建时间	
处置时间	
风险等级	一级、二级、三级
风险类型	10 种风险驾驶行为
处置类型	确认属实、风险误判
处置类型来源	系统默认属实 (超过处置有效时间), 人工核实属实 (有效期内人工处置)
经度	风险驾驶行为发生所在地经度
纬度	风险驾驶行为发生所在地纬度
速度	风险驾驶行为发生时的速度
道路桩号	经纬度与路网数据匹配得到

表 2 交通事故记录数据字段
Table 2 Fields of traffic accidents

字段	说明
车辆 ID	车辆车牌加密后唯一值
事故类型	简单事故、一般事故 (较严重)
事故责任类型	主要、次要、全部、无责等
初查原因	事故初查原因
认定原因	事故认定原因
发生时间	交通事故发生时间
事故地点	交通事故发生地点

graph), 如图 2 所示。RKG 包含的实体可分为客观实体节点与交通泛化实体节点。客观实体节点指客观世界中具有物理存在性的对象, 车辆和业户源自风险驾驶行为数据; 道路桩号和高速公路信息来自路网数据。交通泛化实体节点将动态交通事件抽象为结构化实体, 风险驾驶事件来自风险驾驶行为数据; 交通事故事件来自交通事故记录数据; 风险判定业务规则来自智能监管系统文档。在此基础上, 结合交通领域的专业语义特征, 建立实体间的关联关系网络, 如“车辆—归属—企业”、“风险驾驶行为—发生在一路段”等。作为可解释性关系网络, RKG 将多源异构的车辆风险数据整合为统一的

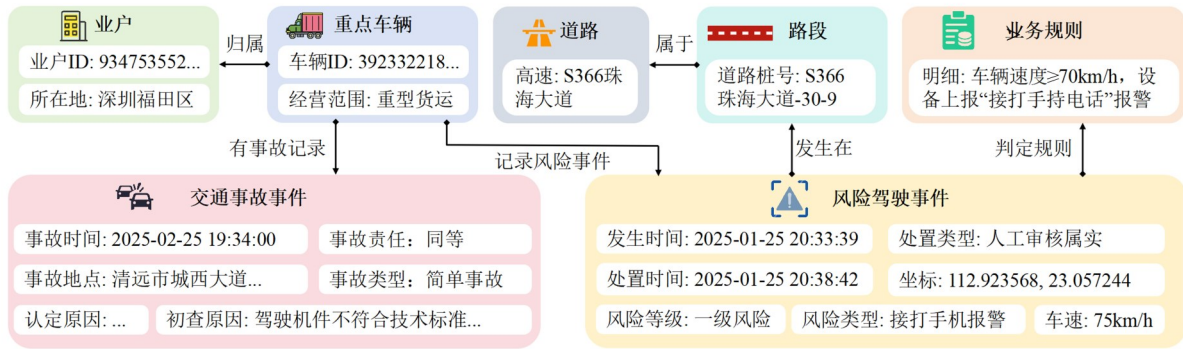


图2 风险知识图谱结构

Fig. 2 Risk knowledge graph structure

结构化知识,为后续LLM的风险分析与智能决策提供语义支撑与可靠性保障。

本文使用Neo4j Community Edition开源图数据库构建风险知识图谱,软件通过图数据库Cypher语言实现节点、关系的创建与查询操作。

2 分级推理思维链

RKG是实现车辆风险数据分析的底座,在数字底座之上搭建LLM与RKG协同融合的数字大脑,为此构造基于提示词工程的分级推理思维链(CoT, chain-of-thought),如图3所示。CoT通过提示词工程内容的动态定义,引导LLM拆分问答任务以实现更高效、可追溯和稳健的推理流程。

2.1 LLM问题需求分析与应答

依托RKG构建的知识图谱数据结构,本文实现了图检索增强生成(GraphRAG, graph retrieval-augmented generation)(Edge et al., 2025)。当对话问题输入后,向量模型(quentinz/bge-large-zh-v1.5)将问题文本转换为语义向量,根据设定的相似度阈值,从知识库中检索相似问题并关联至对应回答。与传统的检索增强生成(RAG)不同,GraphRAG使得系统能够基于图结构的实体关系进行知识检索与推理,可以实现更精准、可解释性更强的知识增强(Hogan et al., 2021)。

CoT将检索到的“问题-回答”知识作为先验知识,传递给提示词框架1并要求LLM进行思考,思考过程可以定义为一个多信息约束的响应函数

$$R_1 = f_{\text{prompt1}}(I_1, Q, D, K_Q, C_1) = \left\{ \left\{ \begin{array}{l} \text{QuestionSolved: true / false} \\ \text{Cypher: null / } C_Q \\ \text{Answer: } A_Q / \text{null} \end{array} \right\} \right\}. \quad (1)$$

将LLM的身份与任务定义为 I_1 ,要求其扮演精通KG查询语言的车辆风险数据分析师,并按照预设JSON格式输出响应 R_1 。LLM接收多源输入:用户问题 Q 、与问题相似的知识 K_Q 、RKG的完整数据库描述 D ,并遵循约束集 C_1 。要求LLM判断是否能够直接、准确地回答 Q :若满足, $QuestionSolved$ 为 $true$,填写答案 A_Q 输出字段, $Query$ 为 $null$;反之,若现有知识不足以解答需要查询RKG,则 $QuestionSolved$ 为 $false$,动态生成查询代码 C_Q , $Answer$ 为 $null$ 。显然,当 $QuestionSolved$ 为 $true$,智能体系统提取 A_Q 返回,结束对话;反之,进行下一阶段。

2.2 LLM问题解答确认与修复

阶段二接收 C_Q 并执行查询, C_Q 和查询结果 R_Q 一起传递给提示词框架2。当查询代码执行报错时, R_Q 为查询执行的报错信息返回结果。阶段二响应函数如公式(2)所示。

$$R_2 = f_{\text{prompt2}}(I_2, Q, C_Q, R_Q, D, K_Q, C_2) = \left\{ \left\{ \begin{array}{l} \text{QuestionSolved: true / false} \\ \text{NewCypher: null / } C_Q \\ \text{Answer: } A_Q / \text{null} \end{array} \right\} \right\}. \quad (2)$$

新身份与任务定义为 I_2 ,要求LLM基于 C_Q 和 R_Q 判断用户问题 Q 是否已获得解答并输出 R_2 :若解答, $QuestionSolved$ 为 $true$,填写答案 A_Q ,不填写 $NewQuery$,智能体系统提取 A_Q 返回,结束对话。反之,由于 R_Q 不满足 Q 的解答需求,或 R_Q 为报错,则 $QuestionSolved$ 为 $true$,LLM需要结合提供的信息反思 C_Q 的问题所在,填写 $NewQuery$ 更新查询代码 C_Q , $Answer$ 不填写。智能体系统再次接收 C_Q 并重新执行查询,更新 R_Q 后LLM重新执行公式(2)的思考过程,形成反思重新验证的推理闭环。

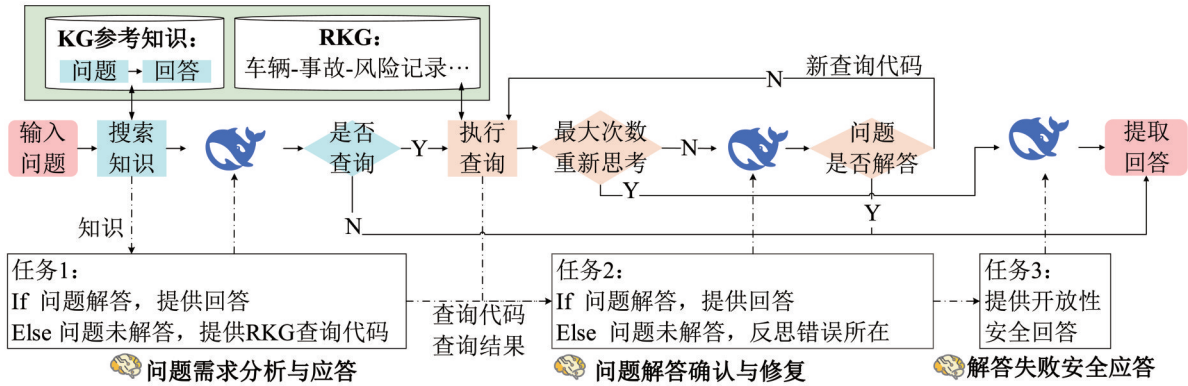


图 3 需求分级推理思维链

Fig. 3 Hierarchical reasoning chain-of-thought

2.3 LLM 解答失败的安全应答

为防止无限的反思重新验证,智能体系统设定了最大反思次数。第 1 次反思后开始计数,当达到反思上限仍未获得有效解答时,阶段三调用提示词框架 3, LLM 结合已有信息给出最终的保底答案的响应函数如公式(3)所示,基于最新 C_0 和 R_0 , K_0 和 D 等信息作为思考辅助,生成开放式的保底安全答案,从而结束对话。

$$R_{last} = f_{prompt3}(I_3, Q, C_0, R_0, D, K_0, C_3) = A_0. \quad (3)$$

3 智能体的可行性和有效性

实验采用的验证数据为广东省重点车辆在 2025 年 1 月 1 日至 6 月 10 日的风险驾驶行为记录数据(以下简称“风险数据”)与交通事故记录数据(以下简称“事故数据”)。数据预处理剔除经判定为误报的风险记录,并仅保留具有明确事故责任认定信息的事故数据。风险数据中的经纬度信息与可计算路网数据进行空间匹配,经纬度信息关联道路桩号的比例为 51.41%。经核实,未能匹配的风险记录发生在路网未覆盖的城市道路及封闭的内部道路。

在图 2 所示结构和验证数据的基础上,本文构建了首个广东省可计算重点车辆风险分析知识图谱,提取车辆实体 246 524 个、业户实体 68 412 个、风险驾驶行为记录实体 1 535 989 条、道路桩号实体 184 104 个、高速公路实体 1 628 个,交通事故记录实体 324 起,有效搭建了结构完整、语义清晰的多源异构车辆风险数据知识化表达框架。

3.1 智能体对话功能验证

评估智能体对从易到难问题的回答能力与推理效果,测试问题如表 3 所示。问题 1 为可基于参考知识直接回答的问题,测试图知识嵌入功能带来的系统快速问答能力;问题 2、3 为简单风险数据查

询问题,测试智能体处理低复杂度查询的能力;问题 4~7 为多条件组合与跨实体关联特征的复杂查询问题,测试智能体的逻辑推理深度与复杂查询构建能力;问题 8、9 为模拟知识边界场景(RKG 未覆盖 2024 年数据,打瞌睡不属于既定风险行为分类),测试智能体对边界问题的鲁棒性或保底回答能力;问题 10~13 代表核心业务风险分析问题,涉及对高风险车辆、企业或路段的综合识别,查询数据需要综合 RKG 结构和风险赋分规则,测试智能体对参考知识 K_0 中预设代码 C_0 的准确复现与执行能力。

本文选取 DeepSeek 系列的 3 款模型进行测试,包括全量对话模型 DeepSeek-V3.1: chat(简称 DS-3.1: chat)、全量推理模型 DeepSeek-V3.1: reasoner(简称 DS-3.1: reasoner)以及蒸馏版本的推理模型 DeepSeek-R1: 32B(简称 DS-R1: 32B)。全量模型通过 DeepSeek 官方 API 使用,蒸馏模型运行在本地 A6000 单卡。表 3 中测试结果采用“√”和“×”标记系统回答的正确性,同时记录反思修正次数和对话用时(单位:s),智能体系统的知识相似度阈值设定为 0.6,最大反思次数设定为 3。

测试结果表明:(1)提示词工程与 CoT 框架发挥了有效的系统支撑作用,全量模型可正确回答全部测试问题。DS-3.1: chat 的整体对话用时最短,随着问题复杂度的提升,各模型的思考时间相应增加,任务逻辑深度对推理耗时具有正向影响。(2) CoT 机制可以增强 LLM 容错能力。DS-R1: 32B 蒸馏模型受限于有限知识, Cypher 语言也有别于传统的 SQL 语言,因此会撰写无效函数方法。如图 4 所示, DS-R1: 32B 模型查询时提供无效“datediff”方法导致问题 6 第 1 次回答失败,修复为“datetime(a. 发生时间).hour”成功查询。对于超出有效数据范围的异常问题 8,最后给出“确认时间范

表 3 测试问题和测试结果
Table 3 Test questions and results

序号	问题内容	K_Q	DS-3.1:chat	DS-3.1:reasoner	DS-R1:32B
1	什么行为属于被检测风险驾驶行为?	有	✓12.13 s	✓48.82 s	✓56.90 s
2	3月17日一共发生了多少起事故,具体位置在哪?	无	✓18.48 s	✓121.10 s	✓28.52 s
3	查询1月风险记录最多的车是哪辆?	无	✓16.91 s	✓140.74 s	✓30.94 s
4	查询哪个业户下属车辆的总风险记录最多?	无	✓15.13 s	✓187.84 s	✓36.44 s
5	统计2月各风险等级事件的数量分布	无	✓16.60 s	✓173.04 s	✓39.93 s
6	查询发生过事故且前1h内有过风险记录的车辆	无	✓27.29 s	✓178.19 s	✓61.15 s反思2次
7	查询4月份深圳业户第1周不同风险驾驶类型的数量	无	✓23.58 s	✓165.45 s	✓75.64 s
8	查询2024年4月发生的事故	有	✓16.44 s	✓47.89 s	✓62.2 s安全回答
9	查询有打瞌睡风险驾驶行为记录的车辆	有	✓14.87 s	✓233.91 s	✓58.44 s
10	请你计算所有车辆风险	有	✓28.95 s	✓283.12 s	✓50.34 s
11	请你计算所有业户风险	有	✓35.06 s	✓257.45 s	✓47.60 s
12	请你提供风险驾驶事件的时间段分布	有	✓37.22 s	✓136.32 s	✓31.95 s
13	请你提供风险驾驶事件的道路分布	有	✓22.87 s	✓288.39 s	✓43.48 s



图 4 DS-R1:32B 撰写无效方法并修复

Fig. 4 DS-R1:32B generates and repairs an invalid method

围”的合理说明,有效避免了幻觉输出。(3)预设的图知识作为参考,有效保障了核心分析任务输出的稳健性与一致性。智能体系统在处理问题10~13均准确复现了预设 C_Q ,未出现代码偏差并完成正确回答。但实验也注意到,全量模型的回答格式相比蒸馏模型更优雅和美观。

准确生成可执行的 Cypher 语句是智能体的主要挑战。实验证明,本文构建的 CoT 机制通过需求判断、动态查询生成、执行反馈与迭代修正等环节,为该挑战提供了系统性的解决方案。得益于 LLM 强大的长文本处理能力,全量对话模型可以胜任 RKG 复杂查询的生成任务,额外使用推理专用模型并未带来性能增益,反而增加了响应延迟与计算开销。轻量化蒸馏模型在保障本地数据隐私与支持边缘部署方面具有重要的应用前景。但是轻量化蒸馏模型在代码生成和推理能力上存在局限。因此,未来研究的重点方向之一是开发面向时空数据知识图谱分析的专业化轻量模型。

3.2 重点车辆关联图谱分析

问题6“查询发生过事故且前1h内有过风险记录的车辆”是实验中重要的时空关联查询任务,可以验证风险驾驶行为与交通事故在时间序列上是否存在显著的因果连续性。DS-3.1:chat 模型为思考引擎,系统解答问题6的完整推理过程如图5所示,前端界面清晰呈现 CoT 的关键执行阶段。总计324起交通事故记录中,仅有2起事故在发生前1h内检测到关联的风险驾驶行为。这说明风险驾驶行为与交通事故之间存在直接时空关联的比例相对较低,交通事故是多种风险因素在特定时空条件下耦合作用的结果,而非单一风险行为的必然结果。

ID 开头为5286的重型货车,在“一般事故”发生前30min,系统记录了该车辆的“抽烟”三级风险报警。以该车辆作为风险分析实例,通过本文开发的重点车辆关联 RKG 子图可视化工具,构建并呈现其核心关联“车—企—路—事”等的多层语义网络,如图6所示。

图6中灰色代表企业,红色代表事故,浅紫色代表风险驾驶行为,橙色代表业务标准,绿色代表道路桩号,蓝色代表高速公路。交互式可视化设计支持鼠标悬停节点查看属性字段,详细属性内容见图2。事故节点显示:初查事故原因“驾车时有其他妨碍安全驾驶的行为”、认定原因为空、事故责任“无责任”。结合“抽烟”风险行为发生于事故前30min,推测交警在事故现场勘查时观察到驾驶员存在吸



图 5 问题 6 解答过程

Fig. 5 Dialogue process for question 6

烟行为,但是事故主因源于第三方车辆或其他外部因素,而非吸烟行为直接导致,真实事故细节需要有关部门确认。

以上基于 RKG 子图的关联分析过程,将离散的风险、事故、企业与路网等多源数据在统一语义框架下进行分析,有效挖掘了单一事件背后的系统性

参考文献:

柏峰, 2022. 道路运输车辆动态监控工作优化改进研究[J]. 运输经理世界, 27: 64-66.

江旭晖, 沈英汉, 李子健, 等, 2023. 社交知识图谱研究综述[J]. 计算机学报, 46(2): 304-330.

李劲业, 李永强, 2024. 融合知识图谱的时空多图卷积交通流

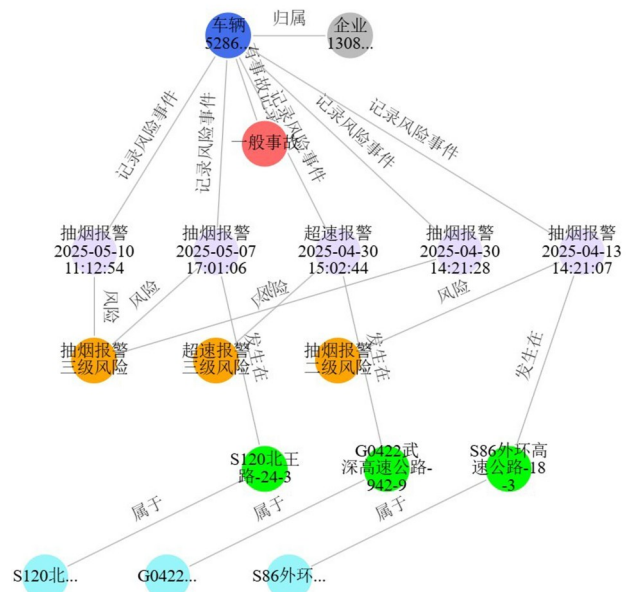


图 6 重点车辆关联 RKG 子图可视化

Fig. 6 Visualization of the RKG subgraph for key vehicles

关联,对提升重点车辆风险监管的精细化、智能化水平具有重要价值。

4 结 语

1) 本文提出了面向重点车辆安全监管的风险知识图谱构建方法,实现并建成广东省可计算重点车辆风险知识图谱。该方法整合车辆、业户、风险驾驶行为、交通事故、路网等多源异构数据,构建“车—企—路—事”的统一知识表达,通过地理空间算法匹配经纬度与路网补充道路桩号,实现“风险行为—事故—路网”的时空关联,同时适配监管业务语义,为交通数据的知识化应用提供了可复现参考。

2) 设计了分级推理思维链机制,研发出车辆风险分析智能体。该智能体形成“理解—查询—验证—修正”可溯源推理闭环,支持自然语言交互,在监管任务中表现优异,框架可迁移至应急管理场景。未来可拓展风险知识图谱的动态性,开发轻量化大语言模型以平衡性能与数据安全。

量预测[J]. 浙江大学学报(工学版), 58(7): 1366-1376.

刘奕含, 宁念文, 杨东霖, 等, 2024. 面向城市交通的动态知识图谱综述——构建、表示与应用[J]. 地球信息科学学报, 26(4): 946-966.

王占中, 兰若冰, 杨萌, 等, 2025. 利用知识图神经推荐算法实

- 时评估危险品道路运输风险[J]. 同济大学学报(自然科学版), 53(8):1253-1261.
- BOUHSISSIN S, SAEL N, BENABBOU F, et al, 2024. SafeSmartDrive: Real-time traffic environment detection and driver behavior monitoring with machine and deep learning[J]. IEEE Access, 12:169499-169517.
- CHEN M, TAO Z, TANG W, et al, 2024. Enhancing emergency decision-making with knowledge graphs and large language models [J]. Int J Disaster Risk Reduct, 113:104804.
- CHEN T, ZHANG Y, QIAN X, et al, 2022. A knowledge graph-based method for epidemic contact tracing in public transportation [J]. Transp Res Part C Emerg Technol, 137:103587.
- EDGE D, TRINH H, CHENG N, et al, 2025. From local to global: A graph RAG approach to query-focused summarization[J/OL]. [2025-02-19]. arXiv.2404.16130.
- GIJRE S, AGRAWAL R, LADDHA P, et al, 2024. Enhancing question-answering with knowledge graph retrieval and generation using LLMs[C]// International Conference on Artificial Intelligence and Quantum Computation-based Sensor Application. Nagpur, India: 1-6.
- HOGAN A, BLOMQUIST E, COCHEZ M, et al, 2021. Knowledge graphs[J]. ACM Comput Surv, 54(4):1-37.
- HOU Y, SHAO Y, HAN Z, et al, 2025. Construction and application of traffic accident knowledge graph based on LLM [R]. SAE Technical Paper Series. <https://doi.org/10.4271/2025-01-7139>.
- JIANG L, XIE W, ZHANG D, et al, 2022. Smart diagnosis: Deep learning boosted driver inattention detection and abnormal driving prediction[J]. IEEE Internet Things J, 9(6):4076-4089.
- LI H, APPLEBY G, ALPERIN K, et al, 2025. The role of visualization in LLM-assisted knowledge graph systems: Effects on user trust, exploration, and workflows [J]. [2025-05-20]. arXiv.2505.21512.
- LIU C, YANG S, 2022. Using text mining to establish knowledge graph from accident/incident reports in risk assessment[J]. Expert Syst Appl, 207:117991.
- PAN S, LUO L, WANG Y, et al, 2024. Unifying large language models and knowledge graphs: A roadmap[J]. IEEE Trans Knowl Data Eng, 36(7):3580-3599.
- QI Z, NI H, 2024. Research on power data analysis algorithms based on knowledge graph and artificial intelligence[C]// The 7th International Conference on Information Systems and Computer Aided Education. Dalian, China:265-271.
- YU D, PENG W, CHEN Y, et al, 2024. Road traffic accident data management and application analysis based on knowledge graph technology [C]//International Conference on Digital Society and Artificial Intelligence. Qingdao, China:297-302.
- ZENG J, TANG J, 2023. Combining knowledge graph into metro passenger flow prediction: A split-attention relational graph convolutional network [J]. Expert Syst Appl, 213:118790.
- ZENG W, HE Z, LU R, et al, 2012. Freeway segment speed estimation model based on distribution features of floating-car data [C]// Transportation Research Board 91st Annual Meeting. Washington DC, United States: 1612-1618.
- ZHAO Z, 2023. Quantification of carbon emission technologies based on knowledge graph bert-BiLSTM-attention-CRF model [C]//International Conference on Electronics and Devices, Computational Science. Marseille, France:42-47.
- ZHU C, WANG Y, WANG Q, et al, 2023. Research on traffic accident prediction based on KG-CWT-RGCNN-BiLSTM[J]. Eng Lett, 31(4):1402-1414.

(责任编辑 王海蓉)