

基于六维语义空间的自动驾驶风险评估研究

陈亚男¹, 李昂², 吴丹³

(1. 南京邮电大学通信与信息工程学院, 江苏 南京 210003;

2. 南京邮电大学空天地海通信技术一体化研究院, 江苏 南京 210003;

3. 陆军工程大学通信工程学院, 江苏 南京 210007)

摘要: 针对自动驾驶中风险要素提取不充分、风险场景评估鲁棒性低等问题, 提出一种基于六维语义空间的风险评估框架, 包括基于六维语义空间的风险要素提取和基于知识图谱的风险场景评估。前者构建六维语义空间并将 RGB 和红外数据映射其中, 利用模态间的关联提取丰富的数据特征, 以获得显在和潜在的风险要素。后者通过语义角色标注和实体融合将风险要素凝练为知识图谱, 并联合节点补全和风险等级函数设计知识图谱推理方法, 实现准确的风险评估。仿真结果表明, 较现有的 MSMatch 和 iSQRT-COV-Net 方法, 所提方法在准确率、漏/虚警率和处理时间上均有优势。

关键词: 六维语义空间; 知识图谱; 风险要素; 风险评估; 自动驾驶汽车

中图分类号: TP391

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024001

Risk assessment of autonomous vehicle based on six-dimensional semantic space

CHEN Yanan¹, LI Ang², WU Dan³

1. College of Telecommunications & Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. Institute of Space-Air-Ground-Sea Integrated Communication Technology, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

3. College of Communications Engineering, Army Engineering University, Nanjing 210007, China

Abstract: To address the problems of inadequate extraction of risk elements and low robustness of risk scenario assessment in autonomous vehicles, a risk assessment framework based on six-dimensional semantic space was proposed, which included risk element extraction based on six-dimensional semantic space and risk scenario assessment based on knowledge graph. Formerly, the semantic space was constructed with RGB and IR data mapped, and rich features were extracted using inter-modal correlations for explicit and potential risk elements. Subsequently, risk elements were distilled into a knowledge graph by semantic role annotation and entity fusion, and an inference method was designed by combining node completion and risk level function for accurate risk assessment. Simulations show that the proposed method surpasses current MSMatch and iSQRT-COV-Net in accuracy, false/missed alarm rate, and processing time.

Keywords: six-dimensional semantic space, knowledge graph, risk element, risk assessment, autonomous vehicle

收稿日期: 2023-07-18; 修回日期: 2023-10-16

通信作者: 吴丹, wujing1958725@126.com

基金项目: 国家自然科学基金资助项目 (No.62231017, No.62122094); 江苏高校优势学科建设工程基金资助项目

Foundation Items: The National Natural Science Foundation of China (No.62231017, No.62122094), Priority Academic Program Development of Jiangsu Higher Education Institutions

0 引言

人工智能技术和自动化技术的飞速发展推动各行各业实现智能化变革，自动驾驶已成为工业界和学术界的研究热点^[1]。近年来，自动驾驶汽车的环境感知、控制系统、路径规划等快速发展。根据国家发改委、中央网信办、工信部等 11 个部委联合印发的《智能汽车创新发展战略》^[2]，到 2025 年，我国将实现高度自动驾驶的智能汽车在特定环境下市场化应用。由此可见，自动驾驶汽车必将成为未来道路交通的主力军。然而，复杂动态的驾驶场景势必会对自动驾驶汽车的安全性提出巨大挑战，从而威胁自动驾驶汽车的市场占有率。如图 1 所示，为了保证自动驾驶的安全性，自动驾驶技术需依靠风险评估来实现潜在风险状况的早期识别，并依此判别交通流中的风险层次和异常场景，以调整驾驶行为^[3]。为此，风险评估逐渐成为自动驾驶技术研究的热点，但鉴于自动驾驶场景的高度复杂性和不可预测性，风险评估仍存在一些挑战。

第一，驾驶场景中信息感知的不准确、不完全，导致风险要素提取需求难以满足。由于驾驶场景复杂多变，诸如自动驾驶汽车的轨迹、速度，汽车之间的相对方向、距离，驾驶环境中汽车的数量、分布及交通流状态等风险要素错综复杂，相互影响。即使路边感知和自动驾驶汽车提供了数据采集的能力，但道路状况、天气状况等环境因素的变化会不可避免地带来信号干扰、传输时延等挑战^[4-6]，导致用于提取风险要素的实时数据仍然存在不准确、不完全的问题。实际上，为了有效地提取风险要素，利用实时数据从多方面挖掘潜在的风险，从而克服感知不确定性是至关重要的。对于自动驾驶，需特别强调在时间和空间维度的特征，以全面了解和描述各种车辆在特定

驾驶场景下的局部风险。此外，有必要通过对结构和内容维度的评估，分析驾驶环境中的车辆分布、交通流状态等全局风险。然而，现有的风险要素提取方法大多利用单目标的两维特征（空间特征、时间特征）进行研究，而对多目标、多维度的研究较少。例如，采用统计学方法^[7]对空间目标特征进行融合，以评估空间目标的威胁程度；通过循环神经网络（RNN, recurrent neural network）^[8-9]识别时间变化中的风险要素。其次，现有的研究大多假设风险要素提取模型中的信息输入是完全的、确定的，而较少考虑信息的不完全性和不确定性。例如，通过深度学习^[10-11]、强化学习^[12]预测道路风险因素，与传统方法不同，该类方法利用大量高质量数据不断训练以提取丰富的特征。尽管取得了一些进展，但是针对信息感知具有局限性的场景，这些方法往往难以同时提取时间、空间、结构、内容等多维度的特征，无法满足自动驾驶场景中全方位感知并提取风险要素的需求。因此，如何从多个维度挖掘潜在的风险信息，以提高风险要素的丰富度是研究的主要挑战。

第二，驾驶场景中对风险要素灵活性、驾驶数据多样性的需求，导致风险场景评估的鲁棒性难以保证。自动驾驶中终端数量庞大，使多源异构数据共存。针对不同的驾驶场景，汽车的状态千变万化，导致每个终端的特征变化极其灵活，难以通过统计学总结规律。现有关于自动驾驶汽车风险评估的工作主要分为两类。

第一类是基于模型的自动驾驶风险评估。根据风险维度不同，该类方法又可分为基于碰撞检测的风险评估和基于单目标下轨迹偏离车道的风险评估^[13]。具体而言，前者的核心是从统计学的角度将风险量化为与另一目标（汽车或行人）相撞的可能性。例如，文献[14]基于动态贝叶斯网络的方法进

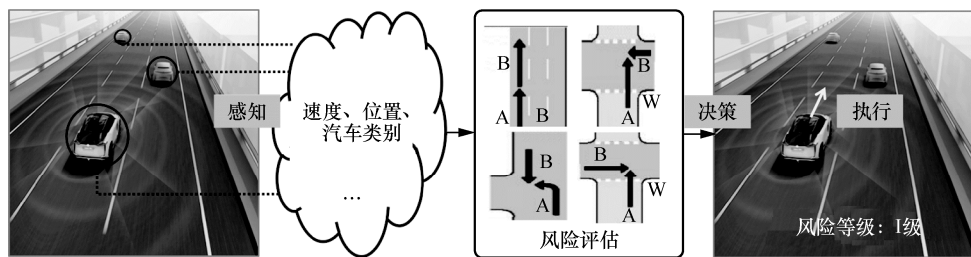


图 1 自动驾驶场景中的驾驶行为调整

行碰撞检测。但鉴于该方法需要大量的高质量数据样本，因而在数据样本不足或不具代表性时，模型的准确性和可靠性会受到影响。为此，有些研究希望通过不断完善数学模型来减少对数据样本的依赖。文献[15-16]以规则为基础，能够快速地对输入进行处理，并产生相对准确高效的结果，但对于高动态场景缺乏鲁棒性。后者的核心是设计预测模型以预见车辆偏离车道的风险及可能引发的安全问题。例如，文献[17]利用概率模型对不确定性建模和推理，在处理高维数据时，它们面临计算复杂度的挑战。进一步，文献[18]基于机器学习模型自动地从数据中学习特征表示，但在处理复杂非线性关系时可能表现较差。为提高模型的表达能力，文献[19-21]利用深度神经网络预测交通参与者的未来位置来实时估计轨迹偏离的概率。值得注意的是，上述工作的共性是通过提取场景中目标间的关系或单目标的行为进行风险评估，未充分考虑场景中风险要素的灵活性和动态性，难以适用于动态复杂的场景。

第二类是基于自动驾驶数据库的风险评估。该类方法依赖于历史驾驶数据和经验信息，通过分析过去的驾驶事件或地图数据来评估风险。例如，文献[22]提出了一种主动互联和自动驾驶汽车网络风险分类模型，并将美国国家漏洞数据库中包含的已知软件漏洞纳入模型构建和测试阶段，以克服缺乏足够的历史信息导致传统的风险评估方法失效的问题。文献[23]通过分析德国深度事故研究数据库来收集知识，以真实世界的事事故数据为依据，提出了一种用于量化特定操作领域中与不同影响因素相关的风险方法。然而，不同自动驾驶数据库中的数据结构各异，带来结构化、半结构化、非结构化数据共存的问题^[24]。具体地，数据的结构和数据的存储形式不同，导致自动驾驶数据库中结构化、半结构化、非结构化数据难以通过统一的格式进行数据整合。此外，不同结构数据的查询方式各异，且不同数据库中的相同字段可能具有不同的含义，使不同数据之间难以表达关联信息。再者，不同数据源的数据可能存在偏差，不同数据之间存在数据重复、不一致或不准确的矛盾，难以保证不同类型的自动驾驶数据共存时的质量。

为了应对上述挑战，本文构建包括基于六维语义空间的风险要素提取和基于知识图谱的风险场

景评估 2 个模块的自动驾驶风险评估框架，主要贡献总结如下。

1) 本文构建包含模态、时间、空间、结构、内容、隶属维度的六维语义空间。通过模态维度挖掘多模态数据间的相关性，以重构丰富的数据特征，进而从时间、空间、结构、内容维度提取潜在风险要素，突出对目标的感知能力，并通过隶属维度的平滑过渡提高风险要素提取的鲁棒性和准确性，由此构建基于六维语义空间的风险要素提取模块，有力解决自动驾驶场景中信息感知不准确、不完全的难题，为后续风险场景评估提供丰富的数据支撑。

2) 本文提出基于知识图谱的风险场景评估方法。基于语义角色标注将六维语义空间中的风险要素提纯为实体和关系，通过三元组的传播和实体融合将风险要素进行融合，获得紧凑、丰富的自动驾驶知识图谱。在此基础上，结合节点补全策略和风险等级函数实现知识图谱推理，以提高动态复杂场景下风险评估的准确性。

3) 本文构建一个包含 RGB 图像、红外图像等多模态数据的自动驾驶数据集，用以验证所提架构的有效性。该数据集能够在各种场景和光照条件下相互补充，具有适应能力强、处理简单的优势。实验表明，较现有的 MSMatch 和 iSQRT-COV-Net 方法，所提方法运用到自动驾驶风险评估中能够使准确率平均提升不低于 3.5%，漏/虚警率平均降低不低于 1.6%，处理时间平均降低 0.029 s。

1 风险评估框架

考虑到信息之间的关联性^[25-28]，本文提出一种基于六维语义空间的风险评估框架，以解决自动驾驶场景中风险要素难以充分提取和风险场景难以准确评估两大挑战。该框架主要包括基于六维语义空间的风险要素提取、基于知识图谱的风险场景评估 2 个模块。本节将结合图 2，从总体上介绍各模块的组成和功能。各模块详细情况将在第 2 节和第 3 节中给出。

1) 基于六维语义空间的风险要素提取模块。首先，构建包括模态、时间、空间、内容、结构、隶属维度在内的六维语义空间。具体地，模态维度挖掘多源异构数据之间的关联性，并依此进行特征重构，以达到统一数据格式、丰富数据特征

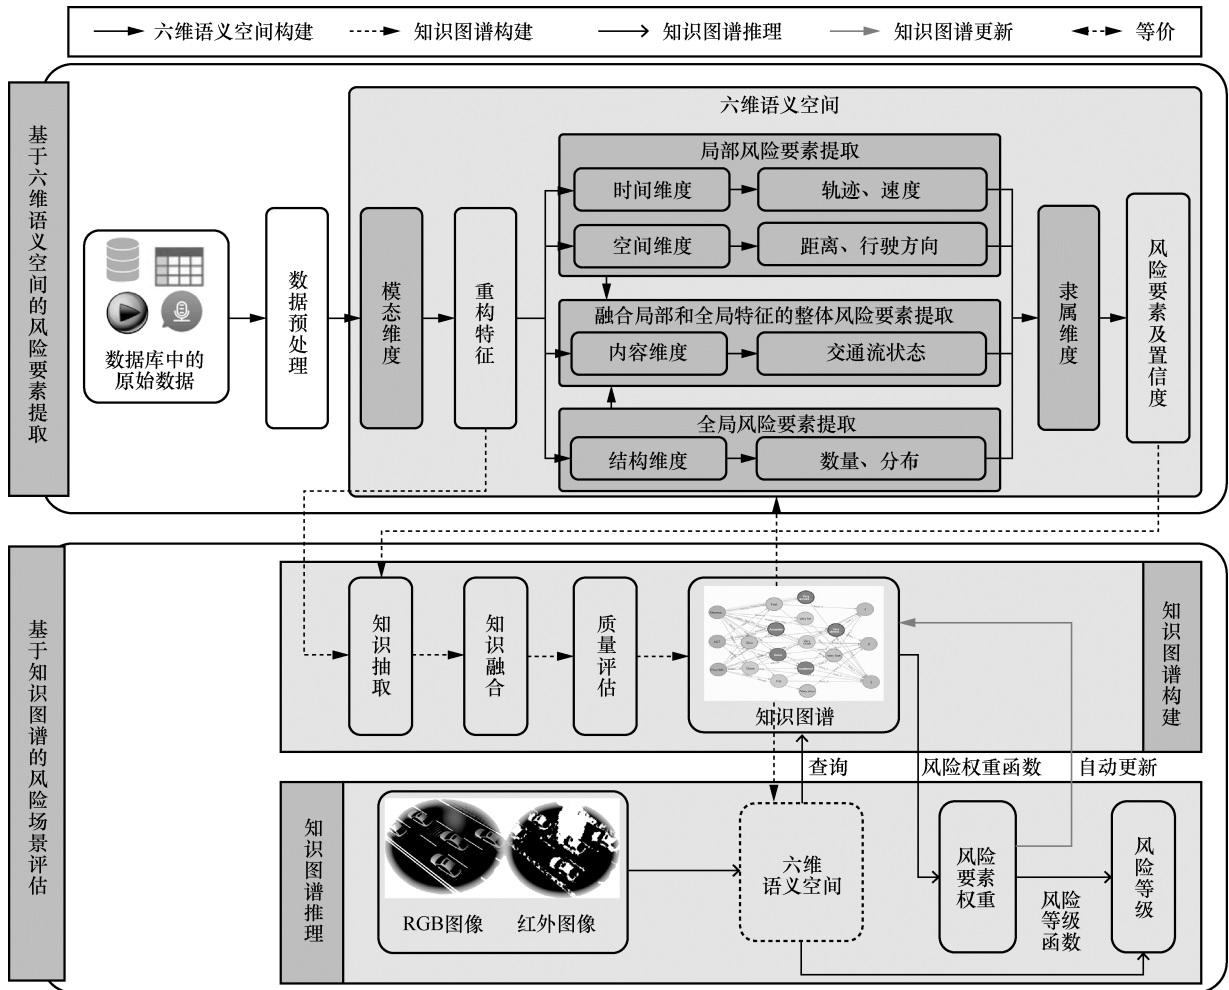


图 2 基于六维语义空间的风险评估框架

的目的。时间维度洞察单目标在不同时刻的动态特征变化，提取时间关联特征，以发现潜在的动态风险。空间维度利用单目标位置信息的变化映射出空间关联信息，依此提取目标的聚集性风险。结构维度通过挖掘多目标之间的关联，分析全局结构关联信息，实现全局风险要素的提取。内容维度融合多尺度特征，以挖掘场景中的隐式信息，进而增强发现潜在风险的能力。隶属维度用于将风险要素进行模糊评价，以保证风险要素提取的准确性和鲁棒性。

将多模态数据输入所构建的六维语义空间中，提取多维度的风险要素。具体地，多模态数据经预处理操作，去除异常数据、整理数据格式，从而得到标准的高质量数据。进一步，利用模态维度重构特征，为时间维度、空间维度、结构维度、内容维度提供丰富的数据来源。时间维度、空间维度、结构维度、内容维度提取自动驾驶场

景中不同属性的潜在风险。其中，时间维度用以提取自动驾驶汽车的轨迹和速度，空间维度用以提取自动驾驶汽车之间的距离和行驶方向，它们均用于局部风险要素提取。结构维度以场景为研究对象，用于提取自动驾驶场景中的全局风险要素，例如，自动驾驶汽车的数量和分布。内容维度融合局部和全局风险要素以提取整体风险要素，例如，交通流状态。最后，隶属维度利用风险要素与聚类中心之间的相似度将上述 4 个维度的风险要素分配到多个风险等级聚类中心，以获取风险要素及其置信度，从而减轻某一风险要素对整体场景的过度影响。

2) 基于知识图谱的风险场景评估模块。该模块主要包括知识图谱构建和知识图谱推理 2 个子模块。在知识图谱构建模块，基于六维语义空间的风险要素提取模块，获得自动驾驶场景中的重构特征、风险要素及其置信度。然后，对提取的

重构特征和风险要素进行结构化处理，并通过知识抽取获得实体和关系。进一步，以知识融合和“实体-关系-实体”的形式融合并链接不同维度的风险要素，实现自动驾驶知识图谱的构建，从而有助于解决数据库中结构化数据难以表达信息关联、半结构化数据难以解析和非结构化数据难以语义化的问题，为准确的风险评估提供数据基础。

在知识图谱推理模块，首先，利用所构建的自动驾驶知识图谱查询各风险要素实体，进而通过节点补全辅助下的语义链推理，实现各风险要素到风险等级的映射。其次，结合风险要素的相对重要性，使用风险权重函数计算各风险要素权重。最后，利用风险等级函数将风险要素和风险要素权重结合，由此计算出该场景的风险值，以实现风险场景评估。同时，风险要素权重的计算结果将反馈给知识图谱，以实现知识图谱的自动更新。

本文所提出的风险评估框架具有的优势总结如下。一方面，六维语义空间的构建使风险要素提取从单维度场景信息扩充为多维度场景信息，为风险评估提供丰富的数据支撑，弥补了信息感知不完全、不准确所带来的风险要素难以有效提取的缺陷。另一方面，自动驾驶知识图谱综合多源数据，为风险评估提供更全面的结构化知识，并通过实体之间的间接关系和路径揭示隐藏的语义关联以增强模型预见潜在风险的能力，进而保证风险评估的准确性。

2 基于六维语义空间的风险要素提取

本节首先提出六维语义空间构建的一般方法，进而针对自动驾驶的具体需求，提出面向自动驾驶的多维风险要素提取方法。

2.1 六维语义空间

如图 3 所示，构建包括模态、时间、空间、结构、内容、隶属维度在内的六维语义空间，具体介绍如下。模态维度表示场景中多源异构信息的特征，其目的在于通过挖掘多模态信号之间的关联性来重构特征，以提高特征算法模型的输入能力。时间维度表示目标随时间变化的连续性特征，其目的在于从目标的轨迹和速度变化中提取时间关联信息，以掌握目标的动态规律，有助于提前发现潜在风险。空间维度表示目标之间存在相对位置差异的聚集性特征，其目的在于通过距离和行驶方向的变化提取空间关联信息，以掌握目标的位置动态性，有助于发现是否存在碰撞风险。结构维度表示目标之间相互关联的内在排列性特征，其目的在于通过分析目标的分布差异提取结构关联特征，以洞察场景中的全局规律，有助于预见不同目标的行为。内容维度表示目标行为反映出其所处环境的主观特征，其目的在于通过场景中整体特征的变化提取内容关联信息，以提高对环境中的隐含状态信息的理解，有助于提取复杂场景的风险要素。隶属维度表示场景中风险要素的置信度特征，其目的在于通过设置软标签使各风险要素的不同等级之间存在

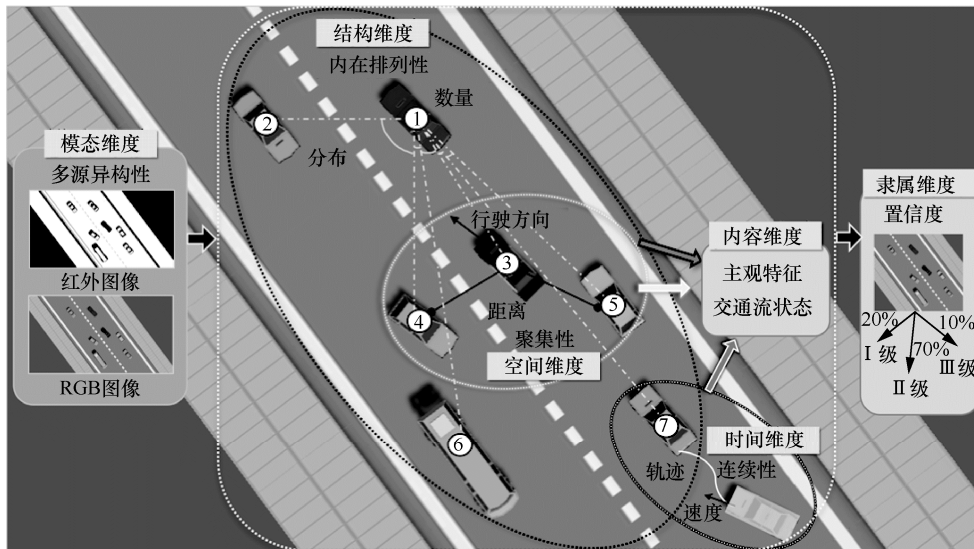


图 3 六维语义空间

一个相对平滑的过渡，以将分类任务转化为概率回归任务，有利于减轻某一风险要素对整个场景的过度影响。

2.2 风险要素提取

2.2.1 模态维度

面对自动驾驶场景中所部署的种类众多的传感器，及其所采集的不同模态数据，模态维度模块用于分析各模态数据在语义层面的相关性，进而理解不同模态数据中目标的特征，并实现不同特征的融合，达到特征丰富的目的。

具体地，由 ViT^[29] 构成特征编码器 $M_E(\cdot)$ ，其采用 6 个 Transformer 块，每个 Transformer 块采用 8 层注意力机制。将能够提供高分辨率的 RGB 图像 V_{RGB} 、具有良好夜间和低光照成像能力的红外图像 V_I 输入特征编码器 $M_E(\cdot)$ ，获得各自的初步特征 f 。进一步，基于 4 层 Transformer 的堆叠，设计特征解码器 $M_D(\cdot)$ 。将初步特征 f 输入特征解码器 $M_D(\cdot)$ ，重构模态关联特征，并提取关键目标的物理特征 $F = \{vh, P, V, r, v, num\}$ ，其中， vh 为汽车类别， P 为汽车的位置， V 为汽车的速度， r 为两汽车之间的距离， v 为汽车的行驶方向， num 为场景中汽车的数量。

2.2.2 时间维度

时间维度着重从汽车的轨迹和速度变化中提取时间关联信息，以此刻画汽车的动态风险程度。具体地，将模态维度所重构的物理特征 F 作为输入，一方面，构建基于长短期记忆 (LSTM) 的轨迹预测模型，获得轨迹风险值 R_{pos} ，即

$R_{pos} = LSTM(F)$ ；另一方面，设计速度映射函数 $T_s(\cdot)$ ，获得速度风险值 R_{spd} ，即 $R_{spd} = T_s(F)$ 。

就轨迹风险值而言，其目的是通过丰富的历史位置信息来预测目标未来某时刻的位置，以完成对轨迹要素的区分和标识，从而提高对潜在风险的可预测性。LSTM 内部具有门机制，可有效处理长期依赖关系，避免传统 RNN 中梯度消失或梯度爆炸的问题^[30]。同时，LSTM 通过记忆单元的状态来存储和更新历史信息，使模型可以利用全局上下文来预测未来轨迹^[31]。鉴于此，本文提出基于 LSTM 的轨迹预测模型，以预测未来时刻的位置信息。如图 4 所示，所建 LSTM 的层数为 2，隐藏层神经元的个数为 32，采用均方误差 (MSE, mean square error) 函数优化模型，则有

$$\text{loss}_{LSTM} = \frac{1}{N} \sum_{i=1}^N (P_i(t) - \hat{P}_i(t))^2 \quad (1)$$

其中， N 表示样本数量， $P_i(t) \in F$ 表示第 i 个样本在 t 时刻的真实位置坐标， $\hat{P}_i(t)$ 表示第 i 个样本在 t 时刻的预测位置坐标。

本文利用 10 个连续时刻的坐标 $\{P(t-10), P(t-9), \dots, P(t-1)\}, t > 10$ 预测下一时刻的目标位置坐标 $\hat{P}(t)$ 。将归一化的损失作为轨迹风险值以用于风险场景评估，记为 R_{pos} ，则有

$$R_{pos} = LSTM(F) = LSTM(P \in F) = \frac{\text{loss}_{LSTM}^{\min} - \text{loss}_{LSTM}^{\max}}{\text{loss}_{LSTM}^{\max} - \text{loss}_{LSTM}^{\min}} \quad (2)$$

其中， $\text{loss}_{LSTM}^{\min}$ 为最小损失， $\text{loss}_{LSTM}^{\max}$ 为最大损失。




图 4 基于 LSTM 的轨迹预测模型

若目标的实际位置与预测位置之间的误差较大，则表示该目标的移动轨迹与预测不相符，其运动出现异常，风险较高；反之，则风险较低。

就速度风险值而言，其目的是利用汽车的运动速度来反映自身的危险程度，即汽车速度越大，其冲击力越强。具体地，受文献[32]启发，设计速度映射函数 $T_s(\cdot)$ ，通过速度标量比值的大小来刻画速度风险值，则有

$$R_{\text{spd}} = T_s(F) = T_s(V \in F) = \begin{cases} 0.1, V_i < 0.6V_a \\ -0.35 + \frac{0.75V_i}{V_a}, 0.6V_a \leq V_i \leq 1.8V_a \\ 1, V_i > 1.8V_a \end{cases} \quad (3)$$

其中， V_i 为目标汽车的速度大小， V_a 为我方汽车的速度大小。

2.2.3 空间维度

空间维度是根据自动驾驶汽车的位置，分析车车间距和行驶方向的特征，以此掌握汽车的潜在碰撞风险。具体地，将模态维度所提取的物理特征 F 作为输入，一方面，建立距离映射函数 $S_p(\cdot)$ ，获得距离风险值 R_{dist} ，即 $R_{\text{dist}} = S_p(F)$ ；另一方面，设计方向映射函数 $S_D(\cdot)$ ，获得方向风险值 R_{direct} ，即

$$R_{\text{direct}} = \frac{S_D(F)}{180^\circ}。$$

就距离风险值而言，其目的是利用车车间相对位置关系的变化来表示危险程度。例如，若两车车间的距离变小，则需要制动减速以防止追尾。与仅考虑两目标间的传统距离指标不同，本文还考虑不同种类汽车的车身长度，并通过设计高内聚、低耦合的映射函数 $S_p(\cdot)$ 来表征距离风险值，则有

$$R_{\text{dist}} = S_p(F) = S_p(r \in F) = \begin{cases} 1 - \frac{0.625r}{r_a}, 0 < r < 0.8r_a, r < r_a < r_i \\ \frac{0.25r}{r_a} - 1.5, 0.8r_a \leq r < r_a, r < r_a < r_i \\ 1 - \frac{r}{r_i}, r < r_i < r_a \end{cases} \quad (4)$$

其中， r_i 为目标汽车的车长， r_a 为我方汽车的车长， r 为双方之间的距离， R_{dist} 为距离风险值，用于风险场景评估。

就方向风险值而言，其目的是通过行驶方向

的变化推测车辆的行为是否存在潜在的碰撞风险^[33-34]。如图 5 所示，由于目标汽车 C_2 紧邻我方汽车 C_3 ，且行驶方向趋近于 C_3 车，行驶方向的变化可能会导致其他车辆急转弯或者突然停车，进而引发连环碰撞等危险情况。为此，本文利用自动驾驶汽车在 2 个时刻位置坐标的向量差值表征汽车的行驶方向。进一步，将我方汽车的行驶方向与目标汽车之间的角度归一化作为行驶方向风险值，则有

$$R_{\text{direct}} = \frac{S_D(F)}{180^\circ} = \frac{S_D(v \in F)}{180^\circ} = \frac{\arccos \frac{v_3(v_2 - v_3)}{|v_3| |v_2 - v_3|}}{180^\circ} \quad (5)$$




图 5 汽车行驶方向说明

以图 5 为例， v_2 和 v_3 分别为目标汽车 C_2 和我方汽车 C_3 的行驶方向。

2.2.4 结构维度

结构维度是从自动驾驶汽车的整体数量和分布特征中提取结构关联信息，以此发现场景中的全局风险。具体地，将模态维度所提取的物理特征 F 作为输入，一方面，构建数量映射函数 $C_N(\cdot)$ ，获得数量风险值 R_{num} ，即 $R_{\text{num}} = C_N(F)$ ；另一方面，设计分布映射函数 $C_D(\cdot)$ ，获得分布风险值 R_{distri} ，即 $R_{\text{distri}} = \frac{C_D(F)}{360^\circ}$ 。

就数量风险值而言，其目的是利用汽车数量衡量道路拥堵程度，反映对行车安全的威胁。一般而言，汽车数量越多，道路越拥堵，风险程度越高。本文从模态维度的识别结果中直接提取汽车数量信息，进而将汽车数量与该场景最大容纳的汽车数量之比记为数量风险值 R_{num} ，则有

$$R_{\text{num}} = C_N(F) = C_N(\text{num} \in F) = \frac{\text{num}}{\text{num}_{\text{max}}} \quad (6)$$

其中, num 为当前场景中的汽车数量, num_{max} 为该场景中最大容纳汽车数量。

就分布风险值而言,其目的是利用聚类思想反映目标汽车所处的环境状态,表征我方汽车被其他汽车包围的程度。一般而言,我方汽车被包围的程度越大,其所处位置越被动,从而风险程度越高。具体地,本文设计一种以汽车为核心的分布识别方法。如图 6 所示,以汽车 O 为中心,计算任意两相邻汽车与汽车 O 之间的夹角之和,并将夹角之和归一化作为分布风险值,则有

$$R_{\text{distri}} = \frac{C_D(F)}{360^\circ} = \frac{C_D(P \in F)}{360^\circ} = \frac{\sum \arccos \frac{P_i P_j}{|P_i| |P_j|}}{360^\circ} \quad (7)$$

其中, P_i 和 P_j 表示任意两相邻汽车的位置坐标。如图 6 所示,场景①较之场景②,其包围角度更大,汽车分布更紧凑拥堵,因而驾驶过程中的风险值更高。




图 6 汽车分布计算说明

2.2.5 内容维度

内容维度融合上述时间维度、空间维度的局部轨迹、速度、距离、方向和结构维度的全局数量、分布等不同尺度的特征,从交通流的状态变化中提取内容关联信息,其目的是利用环境中汽车行为的变化反映隐含的交通流状态信息^[35-36]。

具体地,本文设计基于隐马尔可夫模型(HMM, hidden Markov model)^[37]、人工势场模型、

动态时空图卷积网络(GCN, graph convolutional network)^[38]的投票方法以提取交通流状态。如表 1 所示,上述 3 种方法的原理各异,通过投票机制可以实现不同模型的优势互补。例如,当存在异常数据时,通过多个观察结果的一致性或多数共识来保障结果的准确性。下面详细设计 3 种方法。

表 1 投票机制中不同方法对比

| 方法 | 原理 | 输入 |
|-----------|--------|----------------|
| 隐马尔可夫模型 | 统计学方法 | 时间维度、空间维度、结构维度 |
| 人工势场模型 | 物理学方法 | 模态维度 |
| 动态时空图卷积网络 | 人工智能方法 | 时间维度、空间维度 |

1) 基于 HMM 的交通流状态识别。如图 7 所示,该方法以时间维度、空间维度、结构维度的风险值作为多维度观测数据,使用多个 HMM 模型,并利用 Viterbi 算法分别实现不同维度的行为预测,输出最有可能的隐藏交通流状态,如通畅、拥堵等。最后,综合考虑时间、空间和结构 3 个维度的特征以判断交通流的状态,基于 HMM 的交通流风险值 $R_{\text{behavior}}^{\text{HMM}}$ 表示为

$$R_{\text{behavior}}^{\text{HMM}} = \text{HMM}(R_{\text{pos}}, R_{\text{spd}}) \oplus \text{HMM}(R_{\text{dist}}, R_{\text{direct}}) \oplus \text{HMM}(R_{\text{num}}, R_{\text{distri}}) \quad (8)$$




图 7 基于 HMM 的交通流状态识别

2) 基于人工势场模型的交通流状态识别。类比物理学中电势场的相关概念,人工构造一个基于势场模型的交通流分析模型,称为人工势场。如图 8 所示,在人工势场模型中,把汽车 O 虚拟成电势场中的正电荷,其他汽车虚拟成电势场中的负电荷。自动驾驶中大量汽车将会形成一个“复合电势场”,每一点的“复合电势”将由每辆汽车产生的“虚拟电势”叠加而成。可以通过“复合电势场”来对当前驾驶场景中的全局交通流状态进行实时的分析,即

$$U(t) = \sum \frac{Q}{4\pi\epsilon r(t)} \quad (9)$$

其中,带电量 Q 由不同类型汽车的抗压能力表示, r(t) 为 t 时刻两车之间的距离, ε 为介电常数,且

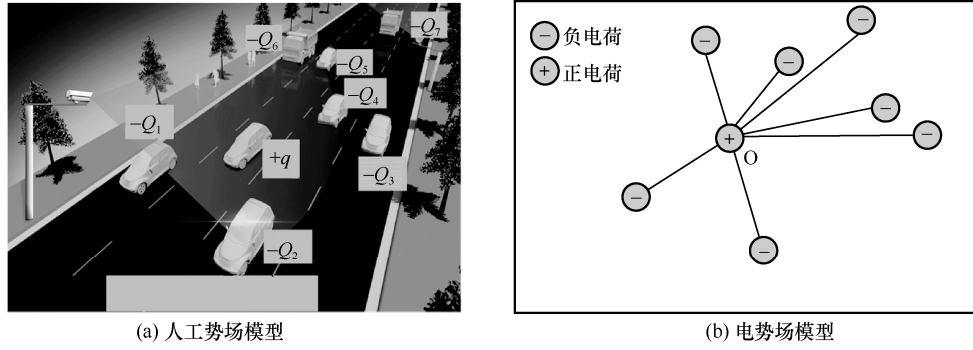


图 8 人工势场与电势场模型对比

$\varepsilon = 8.85 \times 10^{-12}$ 。若 U 减小，表示全局交通流逐渐拥堵；若 U 不变，表示全局交通流状态基本不变；若 U 增大，表示全局交通流逐渐通畅。那么，基于人工势场的交通流风险值表示为

$$R_{\text{behavior}}^U = \begin{cases} 0, & U(t+1) \geq U(t) \\ \frac{U(t) - U(t+1)}{U(t)}, & U(t+1) < U(t) \end{cases} \quad (10)$$

3) 基于动态时空图卷积网络的交通流状态识别。如图 9 所示，该方法将传统的时间序列预测和空间插值估计拓展到时间和空间 2 个维度，并根据这 2 个维度上全局目标的依赖关系进行建模，以提升对这 2 个维度信息的利用率。具体地，首先将每个场景中的汽车建立邻接矩阵，进而将时间维度和空间维度所提取的历史风险值作为各汽车的输入数据，通过动态时空图卷积网络预测全局的交通流状态。采用 MSE 损失函数对模型进行优化，并进一步对其归一化获得基于动态时空图卷积交通流风险值

$$R_{\text{behavior}}^{\text{STGCN}} = \frac{\text{loss}_{\text{STGCN}}^{\text{min}} - \text{loss}_{\text{STGCN}}^{\text{max}}}{\text{loss}_{\text{STGCN}}^{\text{max}} - \text{loss}_{\text{STGCN}}^{\text{min}}} \quad (11)$$

其中， $\text{loss}_{\text{STGCN}}^{\text{min}}$ 为最小损失， $\text{loss}_{\text{STGCN}}^{\text{max}}$ 为最大损失，

$\text{loss}_{\text{STGCN}} = \frac{1}{B} \sum_{i=1}^B (S_i - \hat{S}_i)^2$ ， B 为样本数量， S_i 为真实交通流状态， \hat{S}_i 为预测的交通流状态。




图 9 基于动态时空图卷积的交通流状态识别

最后，为提高内容维度的准确性，融合以上 3 种方法的结果，利用投票函数 $\text{Vote}(\cdot)$ 以多数共识的原则确定交通流风险值，记为 R_{behavior} ，即

$$R_{\text{behavior}} = \text{Vote}(R_{\text{behavior}}^{\text{HMM}}, R_{\text{behavior}}^U, R_{\text{behavior}}^{\text{STGCN}}) \quad (12)$$

2.2.6 隶属维度

隶属维度重点对时间维度、空间维度、结构维度、内容维度的风险要素添加隶属关联信息，其目的是利用风险要素的模糊等级划分来降低风险评估的主观性影响。将时间、空间、结构、内容维度的风险值及预定义的风险等级聚类中心作为输入，一方面，构建风险要素分箱函数 $A_C(\cdot)$ ，获得各维度的风险要素 L ；另一方面，设计模糊评价函数 $A_G(\cdot)$ ，获得风险要素对应的置信度 C 。

具体地，基于领域专家知识定义区间进行风险值分箱，将每个角度的风险值分为 3 级，记为 $L = \{L_{l,h}\} = \{A_C(R_h)\}$ ，其中， $l \in \{1,2,3\}$ 为潜在风险等级， l 越大表示风险越大； $h \in \{\text{pos, spd, dist, direct, num, distri, behavior}\}$ 表示各个风险角度的标签。例如，由式(2)获得的轨迹风险值 R_{pos} ，经过风险分箱得到 3 级风险要素，即 $\{L_{1,\text{pos}}, L_{2,\text{pos}}, L_{3,\text{pos}}\} = A_C(R_{\text{pos}})$ 。通过该模块使风险值实现分区聚类，降低后续知识图谱构建时的分析复杂度。

进一步，利用模糊 C 均值聚类算法^[39]对风险要素等级进行模糊评价，通过为不同维度的风险要素添加置信度，量化每个风险要素对于每个聚类中心的置信程度，并在分类和决策过程中提供更丰富的信息。具体而言，以最小化聚类误差和置信度之间的加权和为目标，对上述 7 组风险要素数据点 $i \in \{1,2,\dots,7\}$ 和 3 个风险等级聚类中心 $j \in \{1,2,3\}$ ，计算其各自隶属度 G_{ij} ，即

$$G_{ij} = A_G(\mathbf{x}_i, \mathbf{s}_j) = \frac{1}{\sum_{k=1}^K \left(\frac{\|\mathbf{x}_i - \mathbf{s}_j\|}{\|\mathbf{x}_i - \mathbf{s}_k\|} \right)^{\frac{2}{m-1}}} \quad (13)$$

其中, $\|\cdot\|$ 为欧氏距离; \mathbf{x}_i 为数据点 i 的特征向量; \mathbf{s}_j 为聚类中心 j 的位置向量; m 为模糊指数, 其控制隶属度的模糊程度, 模糊指数越大, 表示越模糊的隶属度。通过计算每个风险要素和风险等级的隶属度, 获得隶属度矩阵 \mathbf{G} 。进而对隶属度矩阵进行规范化, 获得置信度矩阵 \mathbf{C} , 数据点 i 属于聚类中心 j 的置信度记为

$$C_{ij} = \frac{G_{ij}}{\sum_k G_{ik}} \quad (14)$$

其中, $\sum_j C_{ij} = 1$ 。

3 基于知识图谱的风险场景评估

本节利用六维语义空间提取的风险要素构建知识图谱, 为语义链推理提供依据。进一步, 通过知识图谱推理来挖掘潜在的信息和关联, 以辅助自动驾驶汽车的风险评估。

3.1 知识图谱构建

如图 10 所示, 构建包括知识抽取、知识融合、质量评估在内的知识图谱。特别地, 构建知识图谱的关键是利用模态维度提供的重构特征, 时间、空间维度提供的局部风险要素, 结构、内容维度提供的全局和整体风险要素, 以及隶属维度赋予的置信度, 抽取不同尺度的知识, 并用知识补偿缺失信息, 有助于丰富特征信息, 增强内部特征联系。

1) 知识抽取。本文基于语义角色标注^[40]对多维度风险要素信息进行实体、关系、属性提取。具体地, 经基于六维语义空间的风险要素提取模块获

得重构特征 F 、风险要素 L 及置信度 C , 利用规则匹配进行词法分析, 以识别和抽取出输入数据中的实体 E^l 。然后, 基于预定义的语义角色集合为每个实体生成可能的语义角色候选项。这里, 所设计的自动驾驶语义角色集合表示为 $I = \{vh, dm, cr, dg\}$, 其中, vh 表示汽车类别标签, dm 表示六维语义空间中的不同维度标签, cr 表示每个维度中的风险要素标签, dg 表示不同风险等级标签。在此基础上, 获取不同词性之间的依存关系, 进而抽取出不同角色之间的关系 R_s 。

2) 知识融合。首先, 使用预训练的词向量模型 Word2Vec^[41] 将经知识抽取获得的实体映射为连续的低维向量表示, 并将其对应的风险要素置信度映射为属性值。进一步, 确定是否存在相同实体, 对于相同实体, 则进行融合; 对于不相同实体, 则计算语义相似度。对语义相似的实体进一步查询是否具有相同属性特征, 若是, 则进行融合; 否则计算语义相似度, 且对于语义相似度不低于阈值 e 的两实体进行融合, 以使知识图谱更加紧密。这里, 采用余弦相似度量实体 E_i^l 和 E_j^l 的相似性, 即

$$\text{Sim}(E_i^l, E_j^l) = \frac{E_i^l E_j^l}{\|E_i^l\| \|E_j^l\|} \quad (15)$$

此外, 在风险场景评估过程中, 对于从自动驾驶场景中抽取得到的实体对象, 将其链接到知识库中对应的正确实体对象。最后, 以融合后的实体作为节点, 以关系 R_s 作为边, 构建自动驾驶知识图谱 G_{AV} 。

3) 质量评估。鉴于知识图谱的数据质量和可信度对后续知识推理至关重要^[42-43], 本文从以下 3 个方面对上述知识图谱 G_{AV} 进行质量评估, 以发现和纠正其中的错误。

① 通过对比知识图谱中的事实与源数据中的事实, 修改知识图谱中存在的不一致之处, 即

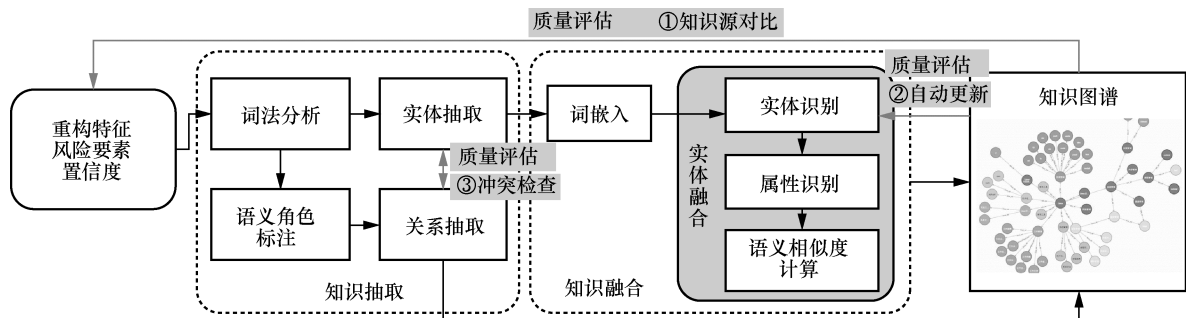


图 10 知识图谱构建

$$G'_{AV} = G_{AV} - (F_G \oplus F_O) \quad (16)$$

其中, G'_{AV} 表示经知识源对比修正过的知识图谱, F_G 表示知识图谱中的事实, F_O 表示源数据中的事实。

②根据自动驾驶场景的变化自动更新知识图谱, 以不断扩展知识, 保证知识图谱的完整性和及时性, 即

$$G''_{AV} = G'_{AV} + F_R \quad (17)$$

其中, G''_{AV} 表示自动更新过的知识图谱, F_R 表示更新的事实。

③通过逻辑推理检查知识图谱中的矛盾并移除相冲突的事实, 例如, 相同实体存在属性值不同或关系类型冲突, 即

$$G'''_{AV} = G''_{AV} - F_C \quad (18)$$

其中, G'''_{AV} 表示经冲突检查的知识图谱, F_C 表示逻辑推理中冲突的事实。

3.2 知识图谱推理

如图 11 所示, 本文联合节点补全和风险等级函数设计知识图谱推理算法, 利用上述已有知识图谱 G'''_{AV} 中的语义关系来推断出自动驾驶场景的风险权重。知识图谱中的知识相互交叉形成逻辑关系, 三元组首尾相连构成的语义链为连贯性推理提供支撑。

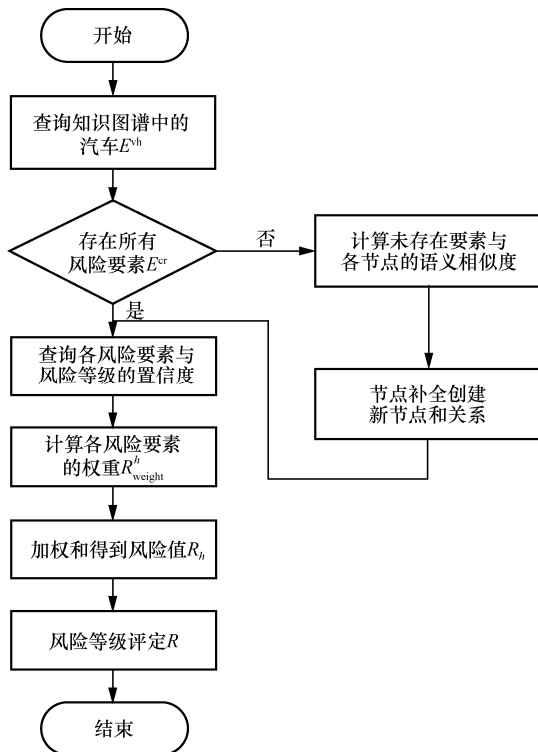


图 11 知识图谱推理流程

特别地, 本文根据风险要素和风险等级之间的隶属关系建立数学模型, 提出了风险权重函数, 即

$$R^h_{weight} = \frac{\max_h C_{l,h} l}{\sum_h \max_h C_{l,h} l}, \quad \forall C_{l,h} \in C \quad (19)$$

其中, $C_{l,h}$ 为风险要素实体 $E_{l,h}$ 与风险等级 l 之间的置信度。风险权重函数根据不同自动驾驶场景下的置信度来动态调整风险权重, 以适应不同情况下风险要素之间的变化关系。

首先, 通过知识图谱查询该自动驾驶场景下用于语义链推理的起始节点, 记为 E^{vh} 。然后, 通过查询知识图谱来确定该场景下的风险要素实体 E^c 是否存在, 其中风险要素实体包括不同维度、不同潜在风险等级的风险要素, 记为 $E^c = \{E_{l,h}\}$, 根据 2.2.6 节可知 $l \in \{1, 2, 3\}$, $h \in \{\text{pos, spd, dist, direct, num, distri, behavior}\}$ 。若存在, 则直接通过式(19)计算各风险要素的权重; 若不存在, 则先利用节点补全策略^[44]更新知识图谱。具体地, 依据形如式(15)的余弦相似度来计算新节点与知识图谱中已存在节点的语义相似度。在此基础上, 利用相关性创建新的节点和关系, 即将语义相似度最高节点的属性赋予新节点, 使知识图谱自动更新实体、关系、属性, 进而实现更可靠的推理。进一步, 通过风险权重函数式(19)计算各风险要素的权重。

最后, 通过风险等级函数对 2.2.6 节中的各个维度的风险值 R_h 进行融合获得该场景的风险等级, 即

$$R = \sum R_h R^h_{weight} \quad (20)$$

并将场景判别结果反馈至六维语义空间和知识图谱以形成闭环体系。

4 性能评估

本节通过实验分析所设计面向自动驾驶场景的风险评估方法的性能, 包括数据集构建、基于六维语义空间的风险要素提取、基于知识图谱的风险场景评估。

4.1 数据集构建

本文构建包含 RGB 图像和红外图像在内的多模态自动驾驶数据集。相较于现有包含图像和激光雷达的多模态自动驾驶数据集^[45-46], 本文构建的数据集能够在各种场景和光照条件下相互补充, 具有适应能力强、处理简单的优势。

具体地, 本文共收集 103 个视频片段, 其中, 每个视频的帧宽度均为 1 920 像素, 帧高度均为 1 200 像素, RGB 图像共 80 037 个, 红外图像共 80 037 个。此外, 本文共标注 17 种汽车类别, 每个标签均为长方形。根据自动驾驶环境中时间与天气的不同, 该数据集被划分为白天晴天、白天雨天、黑夜晴天、黑夜雨天 4 个大类。

4.2 基于六维语义空间的风险要素提取

本文设计的风险要素提取方法可以分为基于深度学习的方法与传统建模方法。传统建模方法适用于参数量少、相对简单的问题, 而深度学习对大量网络参数的拟合能力强。本节以基于深度学习的方法为例, 分析算法提取风险要素及其置信度的性能。

4.2.1 风险要素提取

在风险要素提取中, 本文对时间维度中轨迹预测算法和内容维度中基于投票机制的交通流状态识别算法进行性能分析。

1) 轨迹预测性能分析。本文基于 LSTM 预测汽车的轨迹, 网络训练使用 Adam 进行优化, 设置训练轮数为 100, 学习率为 0.01。输入数据的特征数是 2, 并使用 Pytorch 深度学习框架进行开发, 使用单张 RTX 3060 显卡训练模型。其中, 模型训练过程的损失函数优化曲线如图 12 所示。随着训练轮数的增加, 损失值不断减小, 说明模型的预测能力越来越准确, 训练集的平均误差为 4.7294×10^{-6} 。直到第 63 轮, 模型基本收敛。进一步, 对已训练好的模型进行测试, 轨迹预测结果如图 13 所示。显然, 该模型可以较准确地预测轨迹。




图 12 模型训练过程的损失函数优化曲线 (学习率为 0.01)




图 13 轨迹预测结果

2) 交通流状态识别性能分析。本文基于投票机制对全局交通流状态进行识别。第一, 基于 HMM 的识别中, 设置隐藏状态的数量为 3, 并假设每个输入要素之间是独立的, 分别通过 HMM 预测行为。第二, 基于人工势场模型的识别中, 直接计算叠加势场的大小以识别全局交通流。第三, 基于动态时空图卷积网络的识别中, 本文将每个驾驶场景均分为 10×10 的方格, 以建立维度固定的邻接矩阵。网络训练使用 Adam 进行优化, 设置训练轮数为 100, 批量大小为 50, 学习率为 0.003。使用 Pytorch 深度学习框架进行开发, 使用单张 RTX 3060 显卡训练模型。其中, 模型训练过程的损失函数优化曲线如图 14 所示。


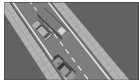







图 14 模型训练过程的损失函数优化曲线 (学习率为 0.003)

本文基于上述 3 种方法对同一驾驶场景的整体交通流状态进行识别。此外, 设计攻击实验以验证投票机制。生成用于攻击模型的异常数据, 包括发生交通事故、车辆不遵守交通规则。将数据注入系统中, 实验结果如表 2 所示。由此可见, 投票机制

表 2 交通流状态识别结果

| 数据类型 | 场景 | 隐马尔可夫模型 | 人工势场模型 | 动态时空图卷积网络 | 识别结果 |
|------|---|---------|--------|-----------|------|
| 正常 |  | 拥堵 | 通畅 | 拥堵 | 拥堵 |
| 正常 |  | 通畅 | 通畅 | 通畅 | 通畅 |
| 正常 |  | 通畅 | 拥堵 | 通畅 | 通畅 |
| 正常 |  | 通畅 | 拥堵 | 拥堵 | 拥堵 |
| 异常 |  | 通畅 | 拥堵 | 拥堵 | 拥堵 |
| 异常 |  | 通畅 | 拥堵 | 拥堵 | 拥堵 |

可集合 3 种方法的优势。特别地，当存在异常数据时，该方法可以维持稳定和准确的识别结果，具有较高的鲁棒性。其中，基于统计学的 HMM 对正常数据的识别能力较强，然而其在高维特征提取方面具有局限性，且高度依赖初始化概率分布矩阵，难以处理异常数据；基于物理学的人工势场模型能够获得对整体车辆的观察，计算量大、实时性差的缺点限制了其在复杂场景下的应用；基于深度学习的图卷积网络需要大量训练，但可以较好地对复杂非线性和非高斯问题进行建模。

4.2.2 置信度提取

本文对隶属维度中的模糊评价进行分析。隶属维度将各风险要素聚类并划分为多个风险等级。具体地，基于模糊 C 均值聚类算法将时间、空间、结构、内容维度的风险要素分别划分为 3 级，置信度划分结果如图 15 所示，当风险值位于区间 (0.28,0.38)和(0.62,0.72)时，风险等级具有模糊性，将会产生相应的置信度。本文通过对比实验验证模糊评价的影响，各风险要素的结果如表 3 所示。相较于对比方法，通过隶属维度的模糊评价能够对风险要素的分级做出更科学、合理、贴近实际的量化评价。

综上所述，本文提出的基于六维语义空间的风险要素提取方法能够有效地挖掘丰富的风险要素，弥补了驾驶场景中信息感知不准确、不完全的不足。




图 15 基于置信度的等级划分结果

4.3 基于知识图谱的风险场景评估

本文基于驾驶场景中的数据构建知识图谱，如图 16 所示。该知识图谱的起始节点为自动驾驶中的汽车，终止节点为风险等级，并以风险要素节点链接起始节点和终止节点，共包括汽车类型、风险要素、风险等级 3 类节点，风险等级划分为 3 级，共构成 12 类风险场景。

本文将从准确率、漏/虚警率和处理时间等方面说明所提框架性能。准确率表示正确推理的样本占总样本的比例，其表征模型正确推理的能力。漏/虚警率表示错误推理和无法推理的样本占总样本的比例，其中错误推理的比例侧面反映出模型的精度，无法推理的比例反映出模型对不同数据的包容能力。处理时间表示模型完成一次推理需要的时间。

表 3 各风险要素的结果

| 场景 | 风险要素 | 模糊评价(置信度) | 无模糊评价 |
|---|---|----------------------|-------|
|  | 轨迹 | 准确(1) | 准确 |
| | 速度 | 慢速(0.35), 标准(0.65) | 标准 |
| | 距离 | 较近(1) | 较近 |
| | 方向 | 角度小(1) | 角度小 |
| | 数量 | 多(0.53), 中等(0.47) | 多 |
| | 分布 | 未包围(0.94), 半包围(0.06) | 未包围 |
| | 交通流 | 拥堵(0.33), 通畅(0.67) | 通畅 |
| |  | 轨迹 | 准确(1) |
| 速度 | | 标准(0.13), 快速(0.87) | 标准 |
| 距离 | | 较近(1) | 较近 |
| 方向 | | 角度中等(1) | 角度中等 |
| 数量 | | 多(0.53), 中等(0.47) | 多 |
| 分布 | | 未包围(1) | 未包围 |
| 交通流 | | 拥堵(0.33), 通畅(0.67) | 通畅 |

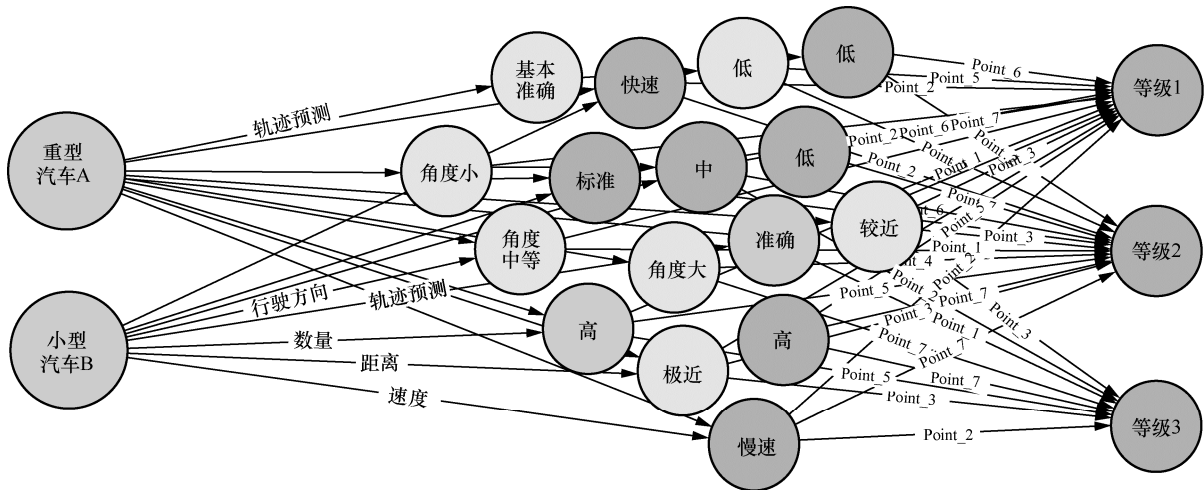


图 16 自动驾驶风险评估知识图谱

间, 其反映模型的复杂度和可用性。此外, 本文选择了如下有代表性的基线 MSMatch^[47]和 iSQRT-COV-Net^[48], 与本文所提方法一起, 在自建自动驾驶数据集上进行测试。

1) MSMatch。它使用多尺度表示来处理不同的特征点, 采用多样的相似度量方法, 如欧氏距离、汉明距离等, 以适应不同的图像特征。此外, MSMatch 方法可以处理部分遮挡、旋转和尺度变化等问题。

2) iSQRT-COV-Net。它将协方差池化与平方根归一化相结合。前者通过计算特征图中不同通道之间的协方差矩阵, 捕捉图像的高阶统计信息; 后者则通过对协方差矩阵进行归一化操作, 降低特征之

间的相关性, 使特征更加稳定。iSQRT-COV-Net 还引入了深度可分离卷积和残差连接等网络结构。

知识图谱推理对比实验结果如表 4 所示。本文所提方法具有多层次推理、隐含关系推理的优势, 使其风险等级判别准确率达到 96.2%, 相较于 iSQRT-COV-Net 和 MSMatch 分别提升了 6.2%和 3.5%。在相同参数配置和数据集上, 漏/虚警率指标相较于 iSQRT-COV-Net 和 MSMatch 分别降低了 10.7%和 1.6%。处理时间相较于 MSMatch 降低了 0.142 s, 相较于 iSQRT-COV-Net 和 MSMatch 的平均处理时间降低了 0.029 s。然而, 复杂场景的风险评估需要遍历大量数据, 导致本文所提方法的处理时间比 iSQRT-COV-Net 高 0.084 s。综上, 考虑到

推理的精度和处理时间，本文所提方法是一种有优势的风险评估方法。

表4 知识图谱推理对比实验结果

| 方法 | 准确率 | 漏/虚警率 | 处理时间/s |
|---------------|-------|-------|--------|
| MSMatch | 92.7% | 7.6% | 0.345 |
| iSQRT-COV-Net | 90.0% | 16.7% | 0.119 |
| 本文所提方法 | 96.2% | 6.0% | 0.203 |

5 结束语

由于自动驾驶场景中信息感知不准确、不完全，且驾驶场景中风险要素极其丰富、灵活，准确的风险评估面临巨大的挑战。为此，本文提出了基于六维语义空间的风险评估方案。首先，本文设计了一种基于六维语义空间的风险评估框架，通过挖掘多模态数据间的关联信息构建六维语义空间，以充分提取风险要素，并进一步提纯凝练为知识图谱，为知识推理提供依据；然后，在此框架下设计了基于六维语义空间的风险要素提取和基于知识图谱的风险场景评估方法；最后，通过实验验证了所提方法的有效性。结果表明，本文所提方法能够提取丰富的风险要素，实现准确的风险评估，从而可以根据潜在风险调整汽车的驾驶行为，提高自动驾驶的安全性能。未来的工作旨在推进自动驾驶风险评估的研究，将深入探讨多维度风险要素之间的相互作用，考虑使用并行计算、优化算法和数据结构等，以加快风险评估和推理的速度，确保系统能够在实时驾驶过程中快速准确地做出决策和调整。

参考文献：

- [1] HUANG Y J, DU J T, YANG Z R, et al. A survey on trajectory-prediction methods for autonomous driving[J]. *IEEE Transactions on Intelligent Vehicles*, 2022, 7(3): 652-674.
- [2] 国家发改委, 中央网信办, 工信部, 等. 智能汽车创新发展战略[R]. 2020.
National Development and Reform Commission, Central Cyberspace Administration, Ministry of Industry and Information Technology, et al. Smart car innovation development strategy[R]. 2020.
- [3] SHI X P, WONG Y D, CHAI C, et al. An automated machine learning (AutoML) method of risk prediction for decision-making of autonomous vehicles[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(11): 7145-7154.
- [4] 田思波, 樊晓旭. 自动驾驶测试场景标准体系建设的思考和思考[J]. *中国标准化*, 2020(4): 87-91.
- [5] TIAN S B, FAN X X. Research and thoughts on establishing the standards system of autonomous driving test scenario[J]. *China Standardization*, 2020(4): 87-91.
- [6] 王若萱, 吴建平, 徐辉. 自动驾驶汽车感知系统仿真的研究及应用综述[J]. *系统仿真学报*, 2022, 34(12): 2507-2521.
- [7] WANG R X, WU J P, XU H. Overview of research and application on autonomous vehicle oriented perception system simulation[J]. *Journal of System Simulation*, 2022, 34(12): 2507-2521.
- [8] 吕品, 许嘉, 李陶深, 等. 面向自动驾驶的边缘计算技术研究综述[J]. *通信学报*, 2021, 42(3): 190-208.
- [9] LYU P, XU J, LI T S, et al. Survey on edge computing technology for autonomous driving[J]. *Journal on Communications*, 2021, 42(3): 190-208.
- [10] LI J X, YUAN L, ZHANG C, et al. Fuzzy dynamic Bayesian network based threat assessment model for space targets[C]//*Proceedings of 2022 5th International Conference on Pattern Recognition and Artificial Intelligence (PRAI)*. Piscataway: IEEE Press, 2022: 1176-1181.
- [11] LIU D P, WANG X, CAI Y, et al. A novel framework of real-time regional collision risk prediction based on the RNN approach[J]. *Journal of Marine Science and Engineering*, 2020, 8(3): 224.
- [12] KOKKOTIS C, MOUSTAKIDIS S, GIAKAS G, et al. Identification of risk factors and machine learning-based prediction models for knee osteoarthritis patients[J]. *Applied Sciences*, 2020, 10(19): 6797.
- [13] HUANG Z Y, LV C, XING Y, et al. Multi-modal sensor fusion-based deep neural network for end-to-end autonomous driving with scene understanding[J]. *IEEE Sensors Journal*, 2021, 21(10): 11781-11790.
- [14] MOZAFFARI S, AL-JARRAH O Y, DIANATI M, et al. Deep learning-based vehicle behavior prediction for autonomous driving applications: a review[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(1): 33-47.
- [15] BHALLA S, GANAPATHI S S, CROWLEY M. Deep multi agent reinforcement learning for autonomous driving[C]//*Proceedings of Canadian Conference on Artificial Intelligence*. Berlin: Springer, 2020: 67-78.
- [16] YU M Y, VASUDEVAN R, JOHNSON-ROBERSON M. Occlusion-aware risk assessment for autonomous driving in urban environments[J]. *IEEE Robotics and Automation Letters*, 2019, 4(2): 2235-2241.
- [17] DAHL J, DE CAMPOS G R, OLSSON C, et al. Collision avoidance: a literature review on threat-assessment techniques[J]. *IEEE Transactions on Intelligent Vehicles*, 2019, 4(1): 101-113.
- [18] PATIL U, RENZAGLIA A, PAIGWAR A, et al. Real-time collision risk estimation based on stochastic reachability spaces[C]//*Proceedings of 2021 20th International Conference on Advanced Robotics (ICAR)*. Piscataway: IEEE Press, 2022: 216-221.
- [19] LI D F, XIAO B, LIN S Y. Lane departure risk assessment for hands-free driving functions[C]//*Proceedings of 2021 5th CAA Inter-*

- national Conference on Vehicular Control and Intelligence (CVCI). Piscataway: IEEE Press, 2022: 1-6.
- [17] ZHU J C, QIN S H, WANG W S, et al. Probabilistic trajectory prediction for autonomous vehicles with attentive recurrent neural process[J]. arXiv Preprint, arXiv: 1910.08102, 2019.
- [18] ZHANG X, MAHADEVAN S. Bayesian neural networks for flight trajectory prediction and safety assessment[J]. *Decision Support Systems*, 2020, 131: 113246.
- [19] CUI H G, RADOSAVLJEVIC V, CHOU F C, et al. Multimodal trajectory predictions for autonomous driving using deep convolutional networks[C]//*Proceedings of 2019 International Conference on Robotics and Automation (ICRA)*. Piscataway: IEEE Press, 2019: 2090-2096.
- [20] CAI P D, SUN Y X, WANG H L, et al. VTGNet: a vision-based trajectory generation network for autonomous vehicles in urban environments[J]. *IEEE Transactions on Intelligent Vehicles*, 2021, 6(3): 419-429.
- [21] CAI Y F, WANG Z H, WANG H, et al. Environment-attention network for vehicle trajectory prediction[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(11): 11216-11227.
- [22] SHEEHAN B, MURPHY F, MULLINS M, et al. Connected and autonomous vehicles: a cyber-risk classification framework[J]. *Transportation Research Part A: Policy and Practice*, 2019, 124: 523-536.
- [23] BABISCH S, NEUROHR C, WESTHOFEN L, et al. Leveraging the GIDAS database for the criticality analysis of automated driving systems[J]. *Journal of Advanced Transportation*, 2023, 2023: 1-25.
- [24] LI A, WEI X, WU D, et al. Cross-modal semantic communications[J]. *IEEE Wireless Communications*, 2022, 29(6): 144-151.
- [25] 李昂, 陈建新, 魏昕, 等. 面向6G的跨模态信号重建技术[J]. *通信学报*, 2022, 43(6): 28-40.
LI A, CHEN J X, WEI X, et al. 6G-oriented cross-modal signal reconstruction technology[J]. *Journal on Communications*, 2022, 43(6): 28-40.
- [26] ZHOU L, WU D, WEI X, et al. Cross-modal stream scheduling for eHealth[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(2): 426-437.
- [27] GAO Y, NI S X, WU D, et al. Edge-based cross-modal communications for remote healthcare[J]. *IEEE Journal on Selected Areas in Communications*, 2022, 40(11): 3139-3151.
- [28] ZHOU L, WU D, CHEN J X, et al. Cross-modal collaborative communications[J]. *IEEE Wireless Communications*, 2020, 27(2): 112-117.
- [29] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: transformers for image recognition at scale[J]. arXiv Preprint, arXiv: 2010.11929, 2020.
- [30] SHU P, CHEN C B, CHEN B H, et al. Trajectory prediction of UAV based on LSTM[C]//*Proceedings of 2021 2nd International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE)*. Piscataway: IEEE Press, 2022: 448-451.
- [31] ROSSI L, PAOLANTI M, PIERDICCA R, et al. Human trajectory prediction and generation using LSTM models and GANs[J]. *Pattern Recognition*, 2021, 120: 108136.
- [32] 常天庆, 赵立阳, 郭理彬, 等. 坦克战+321 场环境多目标威胁评估方法研究[J]. *兵器装备工程学报*, 2019, 40(5): 88-93.
CHANG T Q, ZHAO L Y, GUO L B, et al. Multi target threat assessment method for tank battlefield environment[J]. *Journal of Sichuan Ordnance*, 2019, 40(5): 88-93.
- [33] LI L H, GAN J, JI X K, 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*, 2022, 23(1): 122-141.
- [34] GUI X Y, TODA K, SEO S H, et al. "I am going this way": gazing eyes on self-driving car show multiple driving directions [C]//*Proceedings of the 14th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*. New York: ACM Press, 2022: 319-329.
- [35] 李雅欣. 基于路面参数融合估计的智能越野汽车行驶风险评估研究[D]. 长春: 吉林大学, 2022.
LI Y X. Research on driving risk assessment of intelligent off-road vehicles based on road parameter fusion estimation[D]. Changchun: Jilin University, 2022.
- [36] ENDSLEY M R. Toward a theory of situation awareness in dynamic systems[J]. *Human Factors: the Journal of the Human Factors and Ergonomics Society*, 1995, 37(1): 32-64.
- [37] RABINER L R. A tutorial on hidden Markov models and selected applications in speech recognition[J]. *Proceedings of the IEEE*, 1989, 77(2): 257-286.
- [38] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. arXiv Preprint, arXiv: 1609.02907, 2016.
- [39] RATHEE G, GARG S, KADDOUM G, et al. TrustSys: trusted decision making scheme for collaborative artificial intelligence of things[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(1): 1059-1068.
- [40] 叶琪, 张一乾, 阮彤, 等. 基于语义和结构置信度的知识图谱质量校验方法[J]. *计算机工程*, 2023, 49(5): 48-55.
YE Q, ZHANG Y Q, RUAN T, et al. Quality verification method for knowledge graph based on semantic and structural trustworthiness[J]. *Computer Engineering*, 2023, 49(5): 48-55.
- [41] SADHU A, GUPTA T, YATSKAR M, et al. Visual semantic role labeling for video understanding[C]//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2021: 5585-5596.
- [42] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[J]. arXiv Preprint, arXiv: 1301.3781, 2013.

- [43] 张行, 董荣果, 张亮, 等. 基于知识图谱的质量问题知识库建设研究[J]. 中国标准化, 2022(17): 178-181.
ZHANG H, DONG R G, ZHANG L, et al. Study on the construction of knowledge base of quality issues based on knowledge graph theory[J]. China Standardization, 2022(17): 178-181.
- [44] 吴国栋, 刘涵伟, 何章伟, 等. 知识图谱补全技术研究综述[J]. 小型微型计算机系统, 2023, 44(3): 471-482.
WU G D, LIU H W, HE Z W, et al. Review of knowledge graph completion technology[J]. Journal of Chinese Computer Systems, 2023, 44(3): 471-482.
- [45] MADDERN W, PASCOE G, LINEGAR C, et al. 1 year, 1000 km: the Oxford RobotCar dataset[J]. International Journal of Robotics Research, 2017, 36(1): 3-15.
- [46] PITROPOV M, GARCIA D E, REBELLO J, et al. Canadian adverse driving conditions dataset[J]. The International Journal of Robotics Research, 2021, 40(4/5): 681-690.
- [47] GÓMEZ P, MEONI G. MSMatch: semisupervised multispectral scene classification with few labels[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 11643-11654.
- [48] LI P H, XIE J T, WANG Q L, et al. Towards faster training of global covariance pooling networks by iterative matrix square root normalization[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 947-955.


[作者简介]



陈亚男（1998- ），女，山东济南人，南京邮电大学博士生，主要研究方向为多媒体通信、人工智能。



李昂（1995- ），男，河南周口人，博士，南京邮电大学讲师，主要研究方向为多媒体通信、人工智能。



吴丹（1983- ），女，四川成都人，博士，陆军工程大学教授、博士生导师，主要研究方向为移动通信、多媒体通信。